



TECHNISCHE UNIVERSITÄT MÜNCHEN  
TUM School of Engineering and Design

# Erweiterte Fehlerdiagnose in Lithium-Ionen-Batteriesystemen mit Methoden des maschinellen Lernens

Michael Richard Schmid

Vollständiger Abdruck der von der TUM School of Engineering and Design der Technischen Universität München zur Erlangung eines

**Doktors der Ingenieurwissenschaften (Dr.-Ing.)**

genehmigten Dissertation.

Vorsitz: Prof. Dr.-Ing. Andreas Jossen

Prüfende der Dissertation:

1. Prof. Dr.-Ing. Dr. h. c. Ralph Kennel
2. Prof. Dr.-Ing. Christian Endisch
3. Prof. Dr. rer. nat. Dirk Uwe Sauer

Die Dissertation wurde am 16.01.2023 bei der Technischen Universität München eingereicht und durch die TUM School of Engineering and Design am 04.06.2024 angenommen.





# Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter in der Forschungsgruppe Elektromobilität und Lernfähige Systeme an der Technischen Hochschule Ingolstadt in Kooperation mit der Abteilung für die Entwicklung von HV-Speicher-Konzepten der AUDI AG in Ingolstadt.

Mein herzlicher Dank gilt Herrn Professor Ralph Kennel für seine Betreuung und Unterstützung bei der Durchführung des kooperativen Promotionsverfahrens. Für mich endet mit dieser Arbeit eine langjährige Zugehörigkeit an der Technischen Universität München. Ich möchte mich für diese sehr lehrreiche und prägende Zeit als Student sowie als Doktorand am Lehrstuhl für Elektrische Antriebssysteme und Leistungselektronik bedanken, in der ich Sie als inspirierende Persönlichkeit kennengelernt habe.

Mein besonderer Dank gilt Herrn Professor Christian Endisch, dem Leiter der Forschungsgruppe Elektromobilität und lernfähige Systeme der Technischen Hochschule Ingolstadt für die kontinuierliche Unterstützung, die Betreuung meiner Arbeit und die exzellenten Rahmenbedingungen während meiner Tätigkeit als wissenschaftlicher Mitarbeiter. Besonders schätze ich das mir entgegengebrachte Vertrauen und die wissenschaftliche Freiheit. Beides hat entscheidend zum Erfolg dieser Arbeit beigetragen.

Mein herzlicher Dank gilt all meinen außergewöhnlichen Kollegen des Smart-Cell-Competence-Centers. Einigen Kollegen möchte ich im besonderen Maße danken: Dr. Michael Hinterberger, der stets für fachliche und persönliche Gespräche Zeit gefunden hat. Der Austausch mit Dir war eine Bereicherung meiner Persönlichkeit. Dr. Lidiya Komsyiska für die Übernahme von Reviews und alle Entlastungen. Meinen Weggenossen und Leidensgefährten Bernhard Liebhart, Christoph Terbrack, Christian Hanzl, Dominik Schneider, Julia Stöttner, Christoph Hartmann und Jan Kleiner für die fachlichen Diskussionen, das gute Arbeitsklima und die gemeinsamen Erlebnisse. Aus unserem Kontakt in den letzten vier Jahren sind Freundschaften über die Promotionszeit hinaus entstanden.

Ein weiterer Dank gilt meinen Studenten, insbesondere Herrn Emanuel Gebauer, die mit ihren hervorragenden Leistungen im Rahmen von Studien- und Abschlussarbeiten an meinem Forschungsprojekt mitgewirkt haben.

Schließlich möchte ich mich bei meinen Eltern bedanken, die durch ihre jahrelange bedingungslose Unterstützung den Grundstein für mein Studium und meine Promotion gelegt haben. Zuletzt und im besonderen Maße möchte ich meiner Frau Helena den größten Dank aussprechen: Deine uneingeschränkte und unermüdliche Loyalität gibt mir den Rückhalt für jedes Vorhaben. Dir widme ich diese Arbeit.



# Kurzfassung

Die Fehlerdiagnose zählt zu den zentralen Aufgaben heutiger Batteriemanagementsysteme. Besonders in großen Lithium-Ionen-Batteriepacks, wie sie in elektrischen und hybridelektrischen Fahrzeugen eingesetzt werden, trägt sie entscheidend zum sicheren Betrieb der Energiespeicher bei.

Diese Arbeit beschäftigt sich mit erweiterten Methoden zur Fehlerdiagnose, die über die Einhaltung des sicheren Betriebsbereichs aller Zellen hinausgehen. Als Grundlage zur Entwicklung und Validierung der neuartigen Verfahren und Algorithmen kommt neben Experimenten an Batterieprüfständen ein Modell auf Systemebene zum Einsatz. Die neuartige Matrix-Vektorbasierte Struktur des Modells ermöglicht eine echtzeitfähige Simulation aller Einzelzellen. Sie berücksichtigt dabei die elektro-thermischen Eigenschaften und Alterung auf Zellebene sowie die elektro-thermischen Wechselwirkungen auf Systemebene. Eine Parametrierung anhand realer Zellen erlaubt die Generierung einer breiten Datenbasis, bestehend aus fehlerfreien und fehlerhaften Daten.

Interne Kurzschlüsse stellen heute die häufigste Ursache für Fahrzeugbrände dar und sind der Hauptgrund für Rückrufaktionen von Elektro- und Hybridfahrzeugen. Ziel der erweiterten Fehlerdiagnose ist es, Zellanomalien bereits in der frühen Phase zu erkennen, bevor eine extensive Wärmegenerierung entsteht und ein thermisches Durchgehen unvermeidbar ist. Diese Herausforderung adressiert die vorliegende Arbeit mit der Entwicklung datengetriebener Methoden, basierend auf statistischer Prozessüberwachung, die am Systemmodell und experimentell validiert werden. Da die Methodenentwicklung eine automobiler Anwendung auf Lithium-Ionen-Batteriepacks fokussiert, geht die Arbeit insbesondere auf die damit einhergehenden relevanten Anforderungen ein. Dazu gehört neben der Berücksichtigung von Nichtlinearitäten und Zeitvarianz, ein global robustes Verhalten sowie eine hohe Recheneffizienz der Algorithmen.

Anhand eines rekonfigurierbaren Batteriesystems, das über Schalter auf Zellebene verfügt, untersucht die Arbeit zudem die Vorteile einer aktiven Fehlerdiagnose. Basierend auf einer strukturellen Analyse wird gezeigt, dass Schalthandlungen die Lokalisierung und Identifikation von Fehlern verbessern. Der ganzheitliche Ansatz berücksichtigt neben Zellfehlern auch Sensor- und Elektronik-Fehler. Ermöglicht wird dies durch ein Framework, bestehend aus einem beschränkten Sigma-Punkt-Kalman-Filter, der in der Lage ist, die Vielzahl an Parametern zu schätzen, in Kombination mit einem aktiven Hypothesentest.



# Abstract

Fault diagnosis is one of the central tasks of today's battery management systems. Especially in large lithium-ion battery packs, used in electric and hybrid-electric vehicles, it plays a crucial role in the safe operation of energy storage systems.

This work addresses advanced methods for fault diagnosis beyond maintaining the safe operating range of all cells. A system-level model is used as the basis for developing and validating the novel methods and algorithms, in addition to experiments on battery test benches. The novel matrix-vector-based structure of the model enables real-time simulation of all single cells, taking into account electro-thermal characteristics and aging at the cell level as well as electro-thermal interactions at system level. A parameterization based on real cells allows the generation of a broad database consisting of fault-free and faulty data.

Internal short circuits are the most common cause of vehicle fires nowadays and simultaneously the main reason for recalls of electric and hybrid vehicles. The goal of advanced fault diagnosis is to detect cell anomalies in an early stage, before extensive heat generation occurs and thermal runaway is unavoidable. This work addresses that challenge by developing data-driven methods based on statistical process monitoring, which are validated on the system model and experimentally. Since the method development focuses on an automotive application to lithium-ion battery packs, the work particularly addresses the relevant requirements associated with them. These include the consideration of nonlinearities and time variance, a globally robust behavior as well as a high computational efficiency of the algorithms.

Using a reconfigurable battery system that exhibits cell-level switches, the work also examines the advantages of active fault diagnosis. Based on a structural analysis, it is shown that switching actions improve fault localization and identification. The holistic approach considers cell and electronic faults in addition to sensor faults. This is enabled by a framework consisting of a constrained sigma-point Kalman filter capable of estimating the wide range of parameters, in combination with active hypothesis testing.



*„Six essential qualities that are the key to success:  
Sincerity, personal integrity, humility, courtesy, wisdom, charity.“*

Dr. William C. Menninger





# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
1.1	Stand der Technik in der Fehlerdiagnose von Batteriesystemen . . . . .	2
1.2	Ausgangspunkt und Einschränkungen bestehender Verfahren . . . . .	7
1.3	Zielsetzung und Beiträge dieser Arbeit . . . . .	8
1.3.1	Modellbildung großer Batteriepacks . . . . .	9
1.3.2	Diagnose interner Kurzschlüsse in konventionellen Batteriesystemen .	10
1.3.3	Aktive Fehlerdiagnose in rekonfigurierbaren Batteriesystemen . . . .	11
1.4	Aufbau und Gliederung der Arbeit . . . . .	11
<b>2</b>	<b>Grundlagen der Fehlerdiagnose in Lithium-Ionen-Batteriesystemen</b>	<b>13</b>
2.1	Lithium-Ionen-Batterien . . . . .	13
2.1.1	Aufbau und Funktion . . . . .	13
2.1.2	Wichtige Begriffe und Definitionen . . . . .	17
2.1.3	Batteriemanagement und rekonfigurierbare Batteriesysteme . . . . .	20
2.2	Charakterisierung von Lithium-Ionen-Batterien . . . . .	22
2.2.1	Verwendete Zellen für die experimentellen Untersuchungen . . . . .	22
2.2.2	Identifikation des statischen Batterieverhaltens . . . . .	24
2.2.3	Identifikation des dynamischen Batterieverhaltens . . . . .	27
2.3	Fehler in Batteriesystemen . . . . .	34
2.3.1	Entstehung interner Kurzschlüsse . . . . .	35
2.3.2	Effekte interner Kurzschlüsse . . . . .	37
2.4	Methoden und Definitionen für die Fehlerdiagnose . . . . .	38
2.4.1	Singulärwertzerlegung . . . . .	39
2.4.2	Hauptkomponentenanalyse . . . . .	40
2.4.3	Mahalanobis-Distanz . . . . .	43
2.4.4	Kernel-Methode . . . . .	45
2.4.5	Kerndichteschätzer . . . . .	47
2.4.6	Strukturelle Analyse . . . . .	49
2.4.7	Kalman-Filter . . . . .	50
<b>3</b>	<b>Matrix-Vektor-basierte Modellbildung für große Batteriepacks</b>	<b>55</b>
3.1	Stand der Technik . . . . .	55
3.2	Elektro-thermische Modellierung der Zelle . . . . .	57
3.2.1	Elektrisches Modell . . . . .	57
3.2.2	Thermisches Modell . . . . .	62
3.2.3	Alterungsmodell . . . . .	66
3.3	Modellierung des Batteriepacks . . . . .	69
3.3.1	Stromverteilung bei parallelen Zellen . . . . .	70
3.3.2	Temperaturverteilung im Modul . . . . .	74
3.3.3	Parametervariation . . . . .	76

3.4	Experimentelle Validierung . . . . .	77
3.5	Ergebnisse und Diskussion . . . . .	79
3.5.1	Parametrierung des Zellmodells . . . . .	79
3.5.2	Parametrierung des Batteriepackmodells . . . . .	83
3.5.3	Erkenntnisse für die Fehlerdiagnose . . . . .	85
3.5.4	Simulationsdauer des Modell-Frameworks . . . . .	89
3.6	Graphische Oberfläche des Batteriemodells . . . . .	91
3.7	Ergebnisse und Fazit zum Batteriepackmodell . . . . .	92
<b>4</b>	<b>Datengetriebenes Zellmonitoring zur Diagnose interner Kurzschlüsse</b>	<b>95</b>
4.1	Stand der Technik . . . . .	95
4.1.1	Fehlerdiagnose mit datengetriebenen Methoden . . . . .	95
4.1.2	Detektion von internen Kurzschlüssen . . . . .	97
4.2	Versuchsaufbauten und Datengrundlage . . . . .	99
4.2.1	Spannungseffekte interner Kurzschlüsse und experimentelle Ansätze . . . . .	99
4.2.2	Versuchsaufbau und Messergebnisse mit den PAN-Zellen . . . . .	102
4.2.3	Versuchsaufbau und Messergebnisse mit den SMG-Zellen . . . . .	107
4.2.4	Messdaten von realen Straßenfahrten . . . . .	111
4.2.5	Simulationsdaten aus dem Batteriepackmodell . . . . .	114
4.2.6	Übersicht Datengrundlage . . . . .	116
4.3	Vorverarbeitung der Daten . . . . .	118
4.3.1	Robuste Studentisierung . . . . .	118
4.3.2	Datengrundlage nach der Studentisierung . . . . .	120
4.4	Lineares Zellmonitoring . . . . .	121
4.4.1	Training des Datenmodells . . . . .	122
4.4.2	Fehlerdetektion . . . . .	123
4.4.3	Fehlerisolation . . . . .	126
4.4.4	Berücksichtigung von Nicht-Stationaritäten . . . . .	128
4.4.5	Kreuzvalidierung . . . . .	136
4.5	Nichtlineares Zellmonitoring . . . . .	137
4.5.1	Training des Datenmodells . . . . .	137
4.5.2	Fehlerdetektion . . . . .	142
4.5.3	Wahl der Kernel-Funktionen . . . . .	142
4.5.4	Einfluss lokaler und globaler Kernel-Funktionen . . . . .	146
4.5.5	Anwendung auf das vollständige PAN-Batteriemodul . . . . .	152
4.5.6	Vergleich und Diskussion . . . . .	156
4.5.7	Effiziente Wahl der Trainingsdaten . . . . .	158
4.5.8	Einfluss der Parameter der gemischten Kernel-Funktion . . . . .	167
4.5.9	Fehlerisolation . . . . .	170
4.6	Ergebnisse und Fazit zur datengetriebenen Diagnose interner Kurzschlüsse . . . . .	179
<b>5</b>	<b>Aktive modellbasierte Fehlerdiagnose zur erweiterten Fehlerisolation</b>	<b>183</b>
5.1	Stand der Technik . . . . .	184
5.2	Modell des rekonfigurierbaren Batteriemoduls . . . . .	186
5.2.1	Elektrisches Modell . . . . .	186
5.2.2	Thermisches Modell . . . . .	188
5.2.3	Systemgleichungen . . . . .	189

---

5.3	Strukturelle Analyse und Berechnung von MSO-Teilsystemen . . . . .	191
5.3.1	Isolierbarkeitsanalyse und minimale Sensormenge eines RBS . . . . .	191
5.3.2	Algorithmus zur Berechnung von MSO-Teilsystemen . . . . .	194
5.3.3	Demonstration an einem Beispielsystem . . . . .	200
5.4	Anwendung auf das rekonfigurierbare Batteriemodul . . . . .	202
5.4.1	Resultierende minimale strukturell überbestimmte Teilsysteme . . . . .	202
5.4.2	Versuchsaufbau . . . . .	204
5.4.3	Experimentelle Validierung . . . . .	206
5.4.4	Diskussion und Komplexitätsanalyse . . . . .	207
5.5	Residuenbasierte Parameterschätzung . . . . .	209
5.5.1	Implementierte Residuen . . . . .	209
5.5.2	Beschränkter Parameter-Schätzer . . . . .	210
5.6	Fehlerdiagnose . . . . .	213
5.6.1	Passive Fehlerdetektion und Isolation . . . . .	214
5.6.2	Detektierbarkeitsmaß . . . . .	216
5.6.3	Aktive Fehlerisolation . . . . .	218
5.7	Anwendung auf das Batteriesystem . . . . .	221
5.7.1	Simulative Ergebnisse . . . . .	221
5.7.2	Fehlerfreier Fall . . . . .	224
5.7.3	Interner Kurzschluss . . . . .	227
5.7.4	Erhöhter Kontaktwiderstand . . . . .	229
5.8	Ergebnisse und Fazit zur aktiven Fehlerdiagnose . . . . .	232
<b>6</b>	<b>Zusammenfassung und Ausblick</b>	<b>235</b>
6.1	Modellbildung großer Batteriepacks . . . . .	235
6.2	Diagnose interner Kurzschlüsse in konventionellen Batteriesystemen . . . . .	236
6.3	Aktive Fehlerdiagnose in rekonfigurierbaren Batteriesystemen . . . . .	238
<b>A</b>	<b>Anhang</b>	<b>241</b>
A.1	Messungen an den PAN-Zellen . . . . .	241
A.2	Graphische Oberfläche des Modell-Frameworks . . . . .	244
A.3	Rang-1-Modifikation des symmetrischen Eigenwertproblems . . . . .	245
A.4	Summenumformung zur rekursiven Berechnung der Standardabweichung . . . . .	246
A.5	Zentrierung von Abbildungen im Merkmalsraum $\mathbb{F}$ . . . . .	247
A.6	Rekursiver Bayes-Schätzer . . . . .	248
	<b>Abkürzungen</b>	<b>249</b>
	<b>Symbole</b>	<b>253</b>
	<b>Abbildungsverzeichnis</b>	<b>261</b>
	<b>Tabellenverzeichnis</b>	<b>265</b>
	<b>Literatur</b>	<b>267</b>
	<b>Wissenschaftliche Publikationen des Autors</b>	<b>291</b>



# 1 Einleitung

Die Verbreitung emissionsfreier Fahrzeugtechnologien im Transportsektor spielt eine Schlüsselrolle für die Erreichung des Klimaziels, den Anstieg der globalen Durchschnittstemperatur auf 1.5 °C zu begrenzen. Einen weiteren Treiber neuer Technologien im Verkehrssektor stellt die zunehmende Luftverschmutzung vieler Städte durch eine hohe Verkehrsbelastung dar. Als Lösung rücken neben Brennstoffzellenfahrzeugen derzeit vor allem batteriebetriebene Elektrofahrzeuge (Battery-Electric-Vehicles, BEVs) und Hybridfahrzeuge (Hybrid-Electric-Vehicles, HEVs) als integraler Bestandteil einer nachhaltigen Mobilität im Sinne der Umweltauswirkungen zunehmend in den Fokus von Politik und Gesellschaft. BEVs und HEVs ermöglichen eine signifikante Reduktion der lokalen Emissionen und entlasten auf diese Weise verkehrsreiche Gebiete und Städte. Durch den Betrieb von BEVs und HEVs mit Strom aus erneuerbaren Energien kann der Ausstoß von klimaschädlichen Treibhausgasen, die durch den Verkehrssektor verursacht werden, deutlich reduziert werden [282]. Heutzutage sind für die Energiespeicherung in elektrifizierten Fahrzeugen vor allem Lithium-Ionen-Zellen weit verbreitet [80]. Aufgrund ihrer hohen Leistungs- und Energiedichte, Zuverlässigkeit sowie langen Lebensdauer sind Batteriezellen auf Basis der Lithium-Ionen-Technologie für diese Anwendung prädestiniert [85, 273, 295]. Um die Anforderungen an Reichweite und Leistung zu erfüllen, wird eine große Anzahl von Lithium-Ionen-Zellen parallel und seriell zu einem Batteriepack verschaltet. Zur vollen Ausschöpfung der Vorteile von Lithium-Ionen-Batteriepacks ist es entscheidend, alle Zellen effizient, sicher und ökonomisch zu betreiben [270]. Um einen solchen Betrieb zu gewährleisten, verfügen Batteriepacks über ein Batteriemanagementsystem (BMS), das zusammen mit einer Vielzahl an mechanischen, elektrischen und elektronischen Komponenten das vollständige Batteriesystem darstellt [149, Kapitel 8]. Die grundlegende Aufgabe des BMSs besteht in der Einhaltung des sicheren Betriebsbereichs aller Zellen eines Batteriepacks, das heißt, im Einhalten der zulässigen Spannungs-, Strom- und Temperaturgrenzen sowie im Ausgleichen von Zellunterschieden [178, 260]. Darüber hinaus fordert ein von der Internationalen Elektrotechnischen Kommission (International-Electrotechnical-Commission, IEC) formulierter Standard vom BMS erweiterte Funktionalitäten, wie die Schätzung des Ladezustands, des Batteriealters und der Leistungsfähigkeit sowie eine Fehlerdiagnose, die einen Frühalarm bei defekten Zellen beinhaltet [99, 178]. Tatsächlich stellen fehlerhafte Zellen in großen Batteriesystemen eine ernsthafte Gefahr für die Umgebung dar. Wie aktuelle Studien zeigen, handelt es sich bei den meisten Fehlern um interne Kurzschlüsse (Internal-Short-Circuits, ISCs), die laut Maleki und Howard auch der häufigste Grund für

Fahrzeurückrufaktionen sind [86, 188]. Selbst kleine Fehler, wie ein erhöhter Kontaktwiderstand, führen zu einem ineffizienten Systembetrieb und einer erhöhten Wärmegenerierung, was im schlimmsten Fall zum thermischen Durchgehen einer Zelle führen kann [207]. In Batteriepacks kann das thermische Durchgehen zwischen benachbarten Zellen propagieren und schließlich zu einem Fahrzeugbrand führen [73, 74]. Die Fehlerdiagnose ist daher ein entscheidender Bestandteil eines Batteriesystems, um Langlebigkeit und Sicherheit während der gesamten Betriebszeit zu gewährleisten.

Bei großen Batteriepacks handelt es sich um sehr komplexe Systeme, die ein hohes Maß an Homogenität und Zuverlässigkeit der einzelnen Zellen erfordern. Um die erweiterten Anforderungen an die Zustandsschätzung und Fehlerdiagnose zu erfüllen, sind in letzter Zeit zunehmend Ansätze mit Einzelzell-Sensorik zu finden, bei der jede Zelle über eine individuelle Spannungs-, Strom- und Temperaturmessung verfügt [164, 250]. Die Eingriffsmöglichkeiten des BMSs beschränken sich aber in konventionellen Batteriesystemen in der Regel auf externe Größen wie die Steuerung der Leistungsfähigkeit (Reduzierung des zulässigen Gesamtstroms) oder der Kühlung. Bedingt durch die Bauarchitektur, die Betriebsführung und Zellvariationen nimmt jedoch die Inhomogenität des Batteriesystems im Laufe der Betriebszeit zu. Als eine vielversprechende Lösung für die Herausforderungen in konventionellen Batteriesystemen finden in der Literatur zunehmend rekonfigurierbare Batteriesysteme (RBS) Beachtung [146]. Unter Verwendung von Gleichspannungswandlern oder Schaltern passen sich RBSs dynamisch an aktuelle Betriebsbedingungen an und bieten auf diese Weise eine vielversprechende Möglichkeit, die Anforderungen an die Homogenität der Einzelzellen zu mildern [37, 115, 331]. Intelligente Batteriesysteme (IBSs) kombinieren zellindividuelle Sensorik mit den Rekonfigurationsmöglichkeiten von RBSs. Diese Fusion vereint die präzise Zustandsschätzung und erweiterte Diagnose mit der Möglichkeit, den Stromfluss zellindividuell zu kontrollieren.

## 1.1 Stand der Technik in der Fehlerdiagnose von Batteriesystemen

Aufgrund der Notwendigkeit nach dem IEC-Standard und aktueller Beispiele schwerwiegender Batterieunfälle hat sich die Fehlerdiagnose von Batteriesystemen in den letzten Jahren zu einer eigenen Forschungsdisziplin entwickelt [86]. Die Diagnoseaufgabe selbst lässt sich dabei in vier Stufen unterteilen [17, 59, 104, 127]: Die *Fehlerdetektion* bezieht sich auf die Erkennung beziehungsweise Entdeckung eines Fehlers im System. Die *Fehlerisolation* beinhaltet die Lokalisierung oder Klassifizierung des Fehlers. Die *Fehleranalyse* oder *-identifikation* bestimmt das Ausmaß, die Größenordnung, Amplitude oder Ursache des Fehlers. Darauf aufbauend ermöglicht eine *Fehlertoleranz* schließlich die Fortführung des Betriebs. Der Begriff Fehlerdiagnose beinhaltet in der Regel die Detektion und Isolation von Fehlern. Das Diagnoseziel kann sich je nach eingesetzter Methode und dem zugrundeliegenden System unterscheiden.

Während einige Ansätze den Fehler inhärent isolieren, zielen andere Methoden lediglich auf die Detektion ab. Fehlertoleranz kann in IBSs beispielsweise durch die Rekonstruktion eines fehlerhaften Sensorsignals [51, 250] oder durch die Überbrückung einer Zelle [37, 38] erreicht werden, wenn der Fehler für die Sicherheit des Gesamtsystems nicht relevant ist.

Die Methoden zur Fehlerdiagnose in Batteriesystemen lassen sich in *modellbasierte*, *wissensbasierte* und *datengetriebene* Ansätze unterteilen. Eine Übersicht über die bekannten Ansätze und ihre Anwendung auf Lithium-Ionen-Batterien bieten [123, 178, 260, 278, 295, 303]. Die im Rahmen dieser Arbeit entwickelten Verfahren basieren auf Methoden aus dem Gebiet der modellbasierten und der datengetriebenen Fehlerdiagnose. Aufgrund der umfangreichen Literatur in diesen Bereichen erfolgt an dieser Stelle lediglich ein Überblick und eine Klassifizierung bestehender Methoden sowie eine Zuordnung der diagnostizierten Fehler. Die Abschnitte 4.1 und 5.1 gehen separat und detailliert auf die bestehenden Verfahren und ihre Anwendung zur Diagnose von Lithium-Ionen-Batterien ein. Die hier gezeigte Literaturübersicht ist Bestandteil der Veröffentlichung [146].

Am weitesten verbreitet zur Fehlerdiagnose in Lithium-Ionen-Batteriesystemen sind modellbasierte Methoden. Diese basieren auf einer Zustands- oder Parameterschätzung, dem Paritätsraum oder einer strukturellen Analyse. Bei der Zustandsschätzung rekonstruieren Filter oder Beobachter in einem ersten Schritt das System. Ein Abgleich des Modells mit den Messdaten des Systems liefert dann Residuen, die zur Fehlerdiagnose genutzt werden. Die Algorithmen basieren hierbei meist auf dem Partikelfilter, Kalman-Filter oder einem Zustandsbeobachter (siehe Tabelle 1.1) [278]. Im Rahmen der Parameterschätzung schätzt ein Algorithmus Modell- oder Fehlerparameter basierend auf den Messdaten. Verlässt ein Modell- oder Fehlerparameter seinen fehlerfreien Bereich, so detektiert der Algorithmus einen Fehler. Mit Parameterschätzern ist es daher auch einfacher Fehler zu isolieren, als mit Zustandsschätzern [123]. Paritätsraum-Methoden verifizieren die Beziehung zwischen den Eingangs- und Ausgangsvariablen eines Systems [176]. Die Analyse des resultierenden Residuums ermöglicht eine Fehlerdiagnose des Systems. Die strukturelle Analyse findet, basierend auf den Modellgleichungen, strukturelle überbestimmte Teile eines Systems. Das Ausnutzen von physikalischer oder analytischer Redundanz im System erlaubt die Generierung von Residuen für die Fehlerdiagnose [237].

Wissensbasierte Methoden kommen ohne ein mathematisches oder analytisches Modell aus und sind insbesondere für nichtlineare und komplexe Systeme wie Batteriepacks geeignet [123]. Die Fehlerdiagnose nutzt Beobachtungen und Wissen über Batteriesysteme, das vorher aus Studien über die Fehlermechanismen gewonnen wurde. Aus diesem Grund beschränkt sich hier die Anwendung in erster Linie auf interne Zellfehler, wie Tabelle 1.2 zeigt. Die Ansätze basieren auf der Graphentheorie, Expertensystemen oder Fuzzylogik [278].

Datengetriebene Methoden analysieren direkt die Messdaten des Batteriesystems. Während einige Methoden gänzlich ohne Modell auskommen und sich auf die Extraktion von Merkmalen aus den Messdaten konzentrieren oder eine spezielle Sensortopologie nutzen [137, 297, 298],

Tabelle 1.1: Übersicht modellbasierter Methoden und ihrer Anwendung zur Fehlerdiagnose.

	[237]	[238]	[279]	[195]	[305]	[276]	[323]	[166]	[257]	[156]	[321]	[87]	[54]	[304]	[75]	[256]	[174]	[319]	[306]	[53]	[172]	[76]	[51]	[173]	[262]	[52]	[211]	[175]	[113]	[176]	[171]	[29]	[264]	[2]	[83]	[191]			
Partikelfilter						•	•																																
Kalman-Filter		•						•		•		•		•		•					•			•	•					•			•			•			
Luenberger-Beobachter																										•						•							
Lyapunov-basierte Beobachter																							•																
PDG-basierte Beobachter														•																									
PI-Beobachter				•	•														•																				
Sliding-Mode-Beobachter																				•																•			
Recursive-Least-Squares			•			•			•		•	•		•	•	•						•					•												
Paritätsraum																														•						•			
Strukturelle Analyse	•	•																			•							•			•								
<b>Externe Fehler</b>																																							
Sensorfehler																																							
Spannungssensor	✓	✓	✓			✓	✓	✓						✓			✓			✓	✓			✓				✓	✓	✓	✓					✓			
Stromsensor	✓	✓	✓			✓	✓	✓						✓			✓			✓	✓			✓				✓	✓	✓	✓					✓			
Temperatursensor	✓	✓				✓														✓	✓							✓	✓	✓						✓			
Aktorfehler																																							
Kontakt	✓	✓																✓																		✓			
Kühlsystem													✓										✓			✓		✓				✓					✓		
<b>Interne Fehler</b>																																							
Überladen																																							
Überentladen																									✓										✓				
Kurzschluss																																							
Interner Kurzschluss	✓	✓		✓					✓	✓	✓	✓				✓	✓					✓					✓												
Externer Kurzschluss	✓	✓																																					
Thermischer Fehler																																							
Beschleunigte Degradation													✓										✓			✓											✓		
Widerstandsänderung																																			✓				
Kapazitätsverlust																																							



**Tabelle 1.2:** Übersicht wissensbasierter Methoden und ihrer Anwendung zur Fehlerdiagnose.

	[86]	[309]	[322]	[202]	[296]	[302]	[139]
Regelbasiert	•					•	•
Fuzzylogik				•			•
Random-Forest-Klassifikation		•					
Neuronale Netze			•				
<b>Interne Fehler</b>			✓				
Überladen				✓			✓
Überentladen				✓		✓	✓
Kurzschluss							
Interner Kurzschluss	✓						
Externer Kurzschluss		✓			✓		
Thermischer Fehler							
Beschleunigte Degradation				✓			

lernen andere Methoden ein Datenmodell [240, 241]. Die eingesetzten Algorithmen basieren auf Signalverarbeitung, Neuronalen Netzwerken oder Stützvektormaschinen (Support-Vector-Machines, SVMs) [123]. Zur Signalverarbeitung kommt die Wavelet-Transformation oder Shannon-Entropie zum Einsatz oder Algorithmen analysieren die Korrelation der Signale untereinander. Neuronale Netze können während des Betriebs lernen und haben das Potential rechnerisch effizient zu sein, besitzen jedoch eine schlechte Verallgemeinerungsfähigkeit. Während die Generalisierungsfähigkeit von SVMs deutlich besser ist, kann die benötigte Rechenleistung bei großen Datensätzen schnell ansteigen. Liegt den Daten eine nichtlineare Verteilung zugrunde, kann die Klassifikation eine Transformation durch Kernel-Funktionen erfordern.

Besonderes in IBSs nimmt die Fehlerdiagnose eine zentrale Rolle ein. Durch die vergrößerte Anzahl an Komponenten, steigt auch die Wahrscheinlichkeit des Ausfalls einer Komponente [237]. Beispielsweise erhöht sich die Sensorzahl durch die Einzelzell-Sensorik im Vergleich zu konventionellen Batteriesystemen deutlich. Die zusätzlichen Sensoren erlauben jedoch eine bessere Detektierbarkeit und Isolierbarkeit von Fehlern. So ermöglicht die Vielzahl an Sensoren eine Plausibilisierung von Messwerten und eine Rekonstruktion im Fehlerfall. Die intelligenten Zellen erlauben eine Fehlerdiagnose auf Zellebene. Diese Ausführung ist robust gegenüber Fehlern, die aufgrund der Signalübertragung zum zentralen BMS entstehen. Es ist daher sinnvoll, beispielsweise redundant zum zentralen BMS die Einhaltung des zulässigen Betriebsbereichs auf Zellebene zu überwachen. Für Basisfunktionen wie das Einhalten der Spannungs-, Strom- und Temperaturgrenzen ist dies auch mit beschränkter Rechenleistung möglich. Ein harter externer Kurzschluss lässt sich auf Zellebene detektieren und abschalten [107]. Dagegen sind erweiterte Funktionen, wie die Detektion von internen Kurzschlüssen oder beschleunigte Alterung, auf dem zentralen BMS vielversprechender. Diese Funktionen

**Tabelle 1.3:** Übersicht datengetriebener Methoden und ihrer Anwendung zur Fehlerdiagnose.

	[307]	[311]	[48]	[240]	[56]	[258]	[105]	[208]	[326]	[156]	[137]	[170]	[162]	[148]	[183]	[289]	[299]	[117]	[272]	[297]	[298]	[312]	[63]	[143]	[325]	[62]	[18]	
Wavelet-Transformation														•										•				
Korrelationskoeffizient										•	•		•				•											
Entropie-Theorie						•			•			•			•	•		•	•			•			•			
Sensortopologie											•									•	•							
Inkr. Kapazitätsanalyse																							•		•	•		
CCCV Transformation														•														
Clusteranalyse	•	•			•		•																					
Ausreißererkennung	•		•	•	•		•																					
Neuronale Netze								•																				
<b>Externe Fehler</b>																												
Sensorfehler																												
Spannungssensor				✓							✓									✓	✓							
Stromsensor				✓																								
Temperatursensor																												
Aktorfehler																												
Kontakt		✓	✓	✓							✓			✓					✓			✓			✓			
Kühlsystem																												
<b>Interne Fehler</b>																												
Überladen	✓					✓																						
Überentladen	✓					✓																						
Kurzschluss	✓			✓		✓							✓				✓											
Interner Kurzschluss									✓	✓	✓		✓	✓			✓											
Externer Kurzschluss										✓		✓					✓											
Thermischer Fehler	✓		✓					✓											✓									
Beschleunigte Degradation					✓		✓																		✓			
Widerstandsänderung																												
Kapazitätsverlust																							✓		✓	✓		

benötigen teilweise mehr Rechenleistung oder profitieren vom Vergleich zwischen den Zellen.

## 1.2 Ausgangspunkt und Einschränkungen bestehender Verfahren

Die Entwicklung modellbasierter Diagnoseansätze benötigt ein zuverlässiges und präzises Modell des Gesamtsystems, das als grundlegendes Systemmodell des Verfahrens dient. Aber auch datengetriebene Verfahren profitieren von einem Modell des Batteriepacks, das als Datenlieferant für das Training, die Validierung und den Test der Methoden fungiert. Für die Entwicklung von Algorithmen für IBSs ist es zudem entscheidend, dass das Modell sowohl die zellindividuellen Unterschiede abbildet, als auch auf Systemebene arbeitet. Hierbei stellt sich die Herausforderung in einer sinnvollen Abwägung zwischen Detaillierungsgrad und Rechenaufwand. Wie die Untersuchung der Literatur zu recheneffizienten Modellen auf Systemebene in Abschnitt 3.1 zeigt, besitzen die Modelle auf dem aktuellen Forschungsstand Einschränkungen. Ansätzen, die den gesamten Batteriepack als eine große Zelle betrachten, fehlt der Detaillierungsgrad eines IBS [254, 261]. Andere Literatur fokussiert sich lediglich auf die thermischen oder elektrischen Effekte [23, 61]. Die Ansätze besitzen in ihrer Domäne zwar einen hohen Detaillierungsgrad, der sich jedoch nicht für eine Kosimulation aller Wechselwirkungen auf Systemebene eignet. Gerade elektrochemische Modelle eignen sich eher zur Simulation auf Zellebene und sind, selbst nach Anwendung von Verfahren zur Ordnungsreduktion, nur bedingt auf Batteriepackebene einsetzbar [44]. Auch Ansätze, die Zellen in kleinere Teilzellen unterteilen und diese separat simulieren, besitzen einen hohen Rechenaufwand auf Systemebene [301].

Während der Modellierungsaufwand bei rein datengetriebenen Diagnosemethoden entfällt, haben diese Verfahren häufig Schwierigkeiten damit, kleinere, unvorhergesehene Fehler zu detektieren und eine Fehlerisolation zu ermöglichen [123]. Nicht-modellbasierte Methoden sind auf eine große Menge an Batteriedaten angewiesen. Insbesondere neuronale Netze benötigen zum Training Eingangsdaten, die den gesamten Betriebsbereich der Anwendung abdecken. Aufgrund der Zellalterung, aber auch aufgrund von Temperatur- und Ladezustandsänderungen, ist die Generierung einer solchen Datenbasis schwierig. Eine weitere Herausforderung sind die begrenzten und teuren Rechenkapazitäten der BMS-Hardware, weshalb Methoden mit geringem Rechenaufwand von Vorteil sind. Die Bestimmung der richtigen Schwellenwerte und Parameter ist bei einigen Methoden schwierig, da die Schwellenwerte und Parameter von nicht modellbasierten Ansätzen oft nicht interpretierbar sind [278, 304]. Eine weitere Herausforderung ist die Robustheit hinsichtlich fehlender Anregung oder Sensorrauschen. Besonders bei korrelationsbasierten und entropiebasierten Ansätzen beeinträchtigt Sensorrauschen die Detektionsperformance maßgeblich. Bei Verfahren die auf der Entropie-Theorie basieren, hängt das Diagnoseergebnis stark vom verwendeten Entropiemaß und dem Berechnungsfenster

ab [170, 289]. Zudem erhöht sich der Rechenaufwand mit zunehmender Diagnosegenauigkeit [123]. Datengetriebene Methoden, die auf einer speziellen Sensortopologie basieren, sind nur in Batteriesystemen mit einer solchen einsetzbar [137, 298]. Verfahren, die eine dedizierte Anregung erfordern, sind inhärent nicht während des gesamten Betriebs des Fahrzeugs einsetzbar. Beispielsweise detektiert ein Verfahren, das das Ende der Ladephase analysiert, Fehler erst sehr spät, wenn nur Teilladungen der Batterie erfolgen [148].

Der Großteil der Literatur im Bereich der modellbasierten Fehlerdiagnose befasst sich mit Sensorfehlern des Batteriesystems [32, 53, 172, 174, 304, 306, 323]. Zudem beschränkt sich die Fehlerdiagnose meist auf eine einzelne Zelle [53, 172, 306] oder rein seriell verschaltete Zellen [29, 32, 304], für die angenommen wird, dass sich parallel verbundene Zellen wie eine große Zelle verhalten. Dies vernachlässigt jedoch die Stromverteilung elektrisch paralleler Zellen sowie die Kontakt- und Stromschienenwiderstände. Es gibt also einen Bedarf an Methoden, die in einer ganzheitlichen Betrachtung sowohl Sensor- als auch Parameterfehler für eine Verbindung mehrerer Batteriezellen berücksichtigen. Zudem wurde bisher keiner der modellbasierten Ansätze auf IBSs angewandt, um neben den Zellfehlern auch Bauteilfehler zu diagnostizieren. Insbesondere ist den vorgestellten modellbasierten Ansätzen gemeinsam, dass sie die Sensormessungen passiv nutzen und das Batteriesystem zur Fehlerdiagnose nicht aktiv rekonfigurieren. Da jedoch RBSs über Schalter verfügen, ist es ein vielversprechender Ansatz, diese Schalter vorteilhaft für eine *aktive* Fehlerdiagnose zu nutzen. Chen, Lin u. a. sowie Sampath, Lafortune und Teneketzis modellieren ihr RBS in Form eines Zustandsautomaten (Finite-State-Machine) [31, 232]. Dies ermöglicht die Entwicklung einer Methode zur aktiven strukturellen Fehlerdiagnose. Beide interpretieren alle möglichen Schaltzustände und alle möglichen Fehler als Zustände des endlichen Automaten. Obwohl Chen, Lin u. a. nur zwei mögliche Fehler pro Zelle betrachten, führt der Ansatz im Falle eines größeren IBSs zu einer exponentiellen Komplexität bezüglich der Anzahl der Zellen [31]. Diese Herausforderung macht ihn ungeeignet für ein größeres IBS, dessen Modell aus einer großen Anzahl von Gleichungen besteht. Außerdem berücksichtigt der rein simulativ vorgestellte Ansatz keine Validitätsbedingungen für die Modellgleichungen.

### 1.3 Zielsetzung und Beiträge dieser Arbeit

Aus dem gezeigten Stand der Forschung und den Einschränkungen der bekannten Verfahren leiten sich für die erweiterte Fehlerdiagnose in Batteriesystemen drei grundlegende Ziele ab:

- Das erste Ziel der vorliegenden Arbeit besteht in der elektro-thermischen Modellierung eines großen Batteriepacks auf Einzelzellebene. Um eine Forschung an RBSs und die Simulation von Fehlern zu ermöglichen, muss das Modell in der Lage sein, Parametervariationen sowie die Wechselwirkungen der Zellen zu berücksichtigen. Zur Anwendung als Referenzmodell für modellbasierte Verfahren ist zudem ein geringer Rechenaufwand

entscheidend.

- Das zweite Ziel betrifft die erweiterte Fehlerdiagnose in konventionellen Batteriesystemen. Da ISCs zu den häufigsten Batteriefehlern und Ursachen für einen Batteriebrand zählen, ist eine Frühdetektion dieser Fehler Gegenstand aktueller Forschung. Diese Zielsetzung erfordert von den entwickelten Methoden eine hohe Sensitivität auf beginnende, hochohmige ISCs. Neben der hohen Sensitivität ist jedoch auch eine Robustheit der Methode in Anwesenheit von Alterung und der damit einhergehenden Inhomogenität des Batteriepacks zentral. Für eine Anwendung im BMS spielt neben der Möglichkeit zur Fehlerisolation auch eine geringe Rechenkomplexität der Methode eine entscheidende Rolle.
- Das dritte Ziel dieser Arbeit liegt in der Untersuchung, wie sich die erweiterten Möglichkeiten von RBSs zur Fehlerdiagnose einsetzen lassen. Da RBSs über eine gesteigerte Anzahl an Hardwarekomponenten verfügen, ist neben der Diagnose von Zellfehlern auch die Isolation zwischen Sensor- und Aktorfehlern entscheidend. Um die Komplexitätsprobleme bekannter Ansätze zur strukturellen Analyse von RBSs zu lösen, ist es das Ziel einen Algorithmus zu entwickeln, der für große Systeme mit einer hohen Redundanz geeignet ist.

Die Beiträge dieser Arbeit zum Stand des Wissens und zur Unterstützung der laufenden Forschung fassen die Abschnitte 1.3.1, 1.3.2 und 1.3.3 zusammen. Eine Übersicht der zugehörigen wissenschaftlichen Publikationen des Autors bietet S. 291 f.

### 1.3.1 Modellbildung großer Batteriepacks

Die vorliegende Arbeit erweitert den derzeitigen Forschungsstand im Bereich der Modellbildung von Batteriesystemen um ein neuartiges Matrix-Vektor-basiertes Framework zur effizienten Modellierung und Simulation von großen Batteriepacks. Durch den neuen Modellierungsansatz schafft das Modell den Kompromiss zwischen hoher Detaillierung und geringem Rechenaufwand. Dies bestätigt eine Analyse des Rechenaufwands exemplarisch für die Simulation eines Batteriesystems, bestehend aus 500 Zellen, bei dem alle Zelle ein individuelles elektro-thermisches Modell besitzen und die Wechselwirkungen auf Systemebene berücksichtigt werden. Darüber hinaus berücksichtigt das Modell die zyklische Alterung der Zellen. Diese vielversprechende Kombination ermöglicht sowohl den Online-Einsatz des Modells für Echtzeitanwendungen als auch eine effiziente Simulation bei der Entwicklung großer Batteriesysteme. Der Beitrag dieser Arbeit erweitert die bestehende Literatur zudem um die vollständigen Parametersätze für zwei Zelltypen und die experimentellen Daten zu drei emulierten Fehlerfällen. — Kapitel 3, [245]

### 1.3.2 Diagnose interner Kurzschlüsse in konventionellen Batteriesystemen

Um die in Abschnitt 1.2 aufgezeigten Schwierigkeiten und Einschränkungen bestehender datenbasierter Ansätze zu adressieren, schlägt diese Arbeit eine neuartige Herangehensweise für das datengetriebene Monitoring von Batteriesystemen vor. Basierend auf einer Projektion der Daten mithilfe der Hauptkomponentenanalyse (Principal-Component-Analysis, PCA) erfolgt eine statistische Auswertung zur Fehlerdetektion am Beispiel von ISCs. Den Eingang bilden dabei Zellspannungsdifferenzen, die aus einer gegen Ausreißer robusten Datenvorverarbeitung (Outlier-Robust-Sample-Studentization, ORSS) resultieren. Den adaptiven Schwellwert zur Fehlererkennung ermittelt das Verfahren für ein gegebenes Signifikanzniveau statistisch aus den Daten. Ihre geringe Rechenkomplexität macht die PCA-basierte Überwachung zu einem leistungsfähigen datengetriebenen Werkzeug und prädestiniert sie für große Systeme mit korrelierten Daten. Die Isolierung der fehlerhaften Zelle erfolgt durch die Analyse des Beitrags jeder Zelle zur Fehlerstatistik. Um das nicht-stationäre Batterieverhalten zu berücksichtigen, erweitert eine rekursive Anpassung das Überwachungsverfahren.

Mit zunehmender Alterung vergrößern sich die Parametervariationen der Zellen, was zu größeren und nichtlinear variierenden Zellspannungsunterschieden führt. Um diesen Effekten Rechnung zu tragen, erweitert die vorliegende Arbeit das lineare Überwachungsverfahren mithilfe der kernbasierten Hauptkomponentenanalyse (Kernel-Principal-Component-Analysis, KPCA). Das nichtlineare Datenmodell ist in der Lage, ISCs über den gesamten Ladezustandsbereich und bei Vorliegen von Zellinkonsistenzen frühzeitig zu erkennen. Der Ansatz ist zudem unabhängig von der aktuellen Anregung. Neben der theoretischen Herleitung liefert die Arbeit eine detaillierte Analyse des Verfahrens anhand experimenteller Daten. Basierend auf den gewonnenen Erkenntnissen optimiert der Einsatz gemischter Kernel-Funktionen die Methode, um eine hohe Empfindlichkeit und kurze Erkennungszeit für frühe, hochimpedante, Soft-ISCs und ein robustes Verhalten im Falle von fortgeschrittenen, niederimpedanten ISCs zu erhalten. Das vorgestellte Framework wird experimentell an einem zyklisch und kalendarisch gealterten Modul validiert und mit bestehenden ISC-Erkennungsmethoden verglichen.

Während die Erweiterung auf die KPCA in der Lage ist das nichtlineare Verhalten der Spannungsdifferenzen abzubilden, adressiert die Arbeit auch die Herausforderungen, wie eine hohe Rechenkomplexität und ein erhöhter Bedarf an Trainingsdaten, die mit der nichtlinearen Erweiterung einhergehen. Der Einsatz einer unvollständigen Cholesky-Zerlegung reduziert die Rechenkomplexität deutlich, was eine Online-Anwendung vielversprechend macht. Zudem befasst sich die vorliegende Arbeit mit einer optimalen Wahl der Trainingsdaten. Da die Fehlerisolation im Rahmen der KPCA herausfordernder ist, wird auf die Isolation im nichtlinearen Fall gesondert eingegangen. Dazu stellt diese Arbeit einen Ansatz vor, der eine Fehlerisolation für gemischte Kernel-Funktionen ermöglicht. — Kapitel 4, [235, 239, 240, 241]

### 1.3.3 Aktive Fehlerdiagnose in rekonfigurierbaren Batteriesystemen

Um die exponentielle Komplexität bestehender Ansätze zu vermeiden und die Zuverlässigkeit und Robustheit von RBSs zu erhöhen, entwickelt diese Arbeit einen neuartigen Algorithmus zur aktiven strukturellen Fehlerdiagnose. Basierend auf der Theorie zur strukturellen Analyse findet der Ansatz die kleinsten minimal strukturell überbestimmten Teilsysteme für ein Modul aus rekonfigurierbaren Batteriezellen. Der Algorithmus löst die Komplexitätsprobleme bestehender Ansätze für große Systeme mit hoher Redundanz. Zudem ermöglicht die Berücksichtigung von Validitätsbedingungen den Einsatz in Systemen, deren Struktur sich im Betrieb ändert, wie es durch die Schalter in RBSs der Fall ist. Die darauf aufbauende strukturelle Analyse bietet die Grundlage für eine ganzheitliche Fehlerdiagnose, die Sensorfehler, Aktorfehler und Zellfehler sowie Fehler auf Packebene berücksichtigt. Simulative und experimentelle Untersuchungen an einem rekonfigurierbaren Batteriemodul zeigen die Anwendbarkeit der Methoden.

Das darauf aufbauende Framework zur aktiven Fehlerdiagnose nutzt die Schalter des RBSs vorteilhaft zur Fehlerisolation. In RBSs ändert sich nicht nur der Messraum, sondern auch die Struktur des Batteriesystems. Um dem Rechnung zu tragen, führt die vorliegende Arbeit ein Detektierbarkeitsmaß ein. Die Berücksichtigung von Änderungen in der Detektierbarkeit, abhängig von der Schalterstellung, macht die Fehlerdiagnose robust gegen eine Fehldiagnose bei strukturellen, aber nicht analytisch detektierbaren Fehlern. Eine experimentelle Validierung des Ansatzes an einem Batteriemodul zeigt die Möglichkeit des Frameworks, neben Sensorfehlern auch Parameterfehler und Fehler in den elektrischen Bauteilen zu isolieren. Eine Erweiterung bekannter Ansätze ermöglicht die Wahl einer optimalen Schaltfolge zur Fehlerisolation, unabhängig von der zu erwartenden Fehleramplitude nach dem Schalten. Die Anpassung erhöht die Robustheit gegenüber Fehlern in der Kernel-Schätzung. Nach der erfolgreichen Isolation schätzt der Algorithmus dennoch die Fehleramplitude zur Fehleranalyse. — Kapitel 5, [237, 238]

## 1.4 Aufbau und Gliederung der Arbeit

**Kapitel 2** gibt eine Einführung in die Grundlagen zur Fehlerdiagnose in Lithium-Ionen-Batterien. Neben der grundlegenden Funktionsweise von Batteriezellen und der Parametrierung von Modellen geht das Kapitel auch auf mögliche Zellfehler und die Werkzeuge zur Fehlerdiagnose ein, die diese Arbeit verwendet.

Modellbasierte Verfahren benötigen ein Modell des zugrundeliegenden Systems. Aber auch datengetriebene Verfahren profitieren im Training von einem effizienten Systemmodell, das in der Lage ist, ein vollständiges Batteriesystem in jedem Betriebszustand zu beschreiben. Aus diesem Grund befasst sich **Kapitel 3** mit der Modellbildung großer Batteriespeicher. Dazu

führt das Kapitel zunächst die neue Matrix-Vektor-basierte Modellstruktur ein, parametrisiert diese anhand zweier Zelltypen und validiert sie anhand verschiedener Fehlerfälle. Eine graphische Oberfläche erlaubt zu jedem Zeitpunkt einen Einblick in die zellinternen Zustände, sowie eine benutzerfreundliche Generierung von System- und Fehlerdaten.

**Kapitel 4** stellt einen datengetriebenen Ansatz, basierend auf statistischer Prozessüberwachung vor, der interne Kurzschlüsse in einer frühen Phase detektiert. Die Validierung erfolgt, neben den Fehlerdaten aus dem Systemmodell, anhand eines experimentellen Prüfstands und realer Fahrzeugdaten. Um den Anforderungen der automobilen Anwendung gerecht zu werden, adressiert das Kapitel die damit einhergehenden Herausforderungen: Das Monitoring von Batteriezellen erfordert einen Umgang mit Zeitvarianz, Nichtlinearitäten und nicht-normalverteilten Daten. Für die Anwendung ist darüber hinaus ein global robustes Verhalten und, aufgrund beschränkter Rechenkapazitäten, ein recheneffizientes Monitoring entscheidend. Zudem geht das Kapitel auf eine Pareto-effiziente Wahl der Hyperparameter sowie die Lokalisierung fehlerhafter Zellen ein.

Während konventionelle Batteriesysteme lediglich eine passive Diagnose über die Sensorik erlauben, ermöglichen rekonfigurierbare Batteriesysteme durch ihre Aktorik eine aktive Diagnose durch Veränderung der Systemstruktur. Um das Potential dieses zusätzlichen Freiheitsgrads abzuschätzen, analysiert **Kapitel 5** diese neuartige Systemstruktur zunächst strukturell. Die gewonnenen Einblicke erlauben das Finden optimaler Sensor-Mengen und minimal strukturell überbestimmter Teilsysteme, die eine einfache Generierung von Residuen zur modellbasierten Fehlerdiagnose erlauben. Das eingesetzte Sigma-Punkt-Kalman-Filter (SPKF) erlaubt neben der erforderlichen Zustands- und Parameterschätzung eine Fehlerdetektion und -isolation. Die Isolierbarkeit von Fehlern verbessert darüber hinaus ein aktiver Hypothesentest, basierend auf den Schaltern des RBSs. Der experimentelle Prüfstand eines rekonfigurierbaren Batteriemoduls demonstriert die Vorteile des RBSs anhand ausgewählter Fehler.

Abschließend fasst **Kapitel 6** die Ergebnisse und gewonnenen Erkenntnisse zusammen und gibt einen Ausblick auf zukünftige Erweiterungen und Forschungsfragen.



---

## 2 Grundlagen der Fehlerdiagnose in Lithium-Ionen-Batteriesystemen

Dieses Kapitel stellt die Anwendung und grundlegende Werkzeuge für die Fehlerdiagnose vor, auf denen diese Arbeit basiert. Während Abschnitt 2.1 Lithium-Ionen-Zellen und -Batteriesysteme grundlegend einführt, geht Abschnitt 2.2 auf die Charakterisierung von Zellen und Abschnitt 2.3 auf Batteriefehler ein. Abschnitt 2.4 ergänzt die Grundlagen um Methoden, Algorithmen und wichtige Definitionen, auf die die Diagnoseverfahren dieser Arbeit aufbauen.

### 2.1 Lithium-Ionen-Batterien

Eine erfolgreiche Fehlerdiagnose erfordert die Kenntnis der zugrundeliegenden Anwendung. Für die vorliegende Arbeit sind dies elektrochemische Energiespeicher, deren prinzipiellen Aufbau und Funktionsprinzip dieser Abschnitt einführt. Die Batteriepacks von Elektro- und Hybridfahrzeugen bestehen aus einer Vielzahl an Einzelzellen, weshalb auch die Systemebene beleuchtet wird.

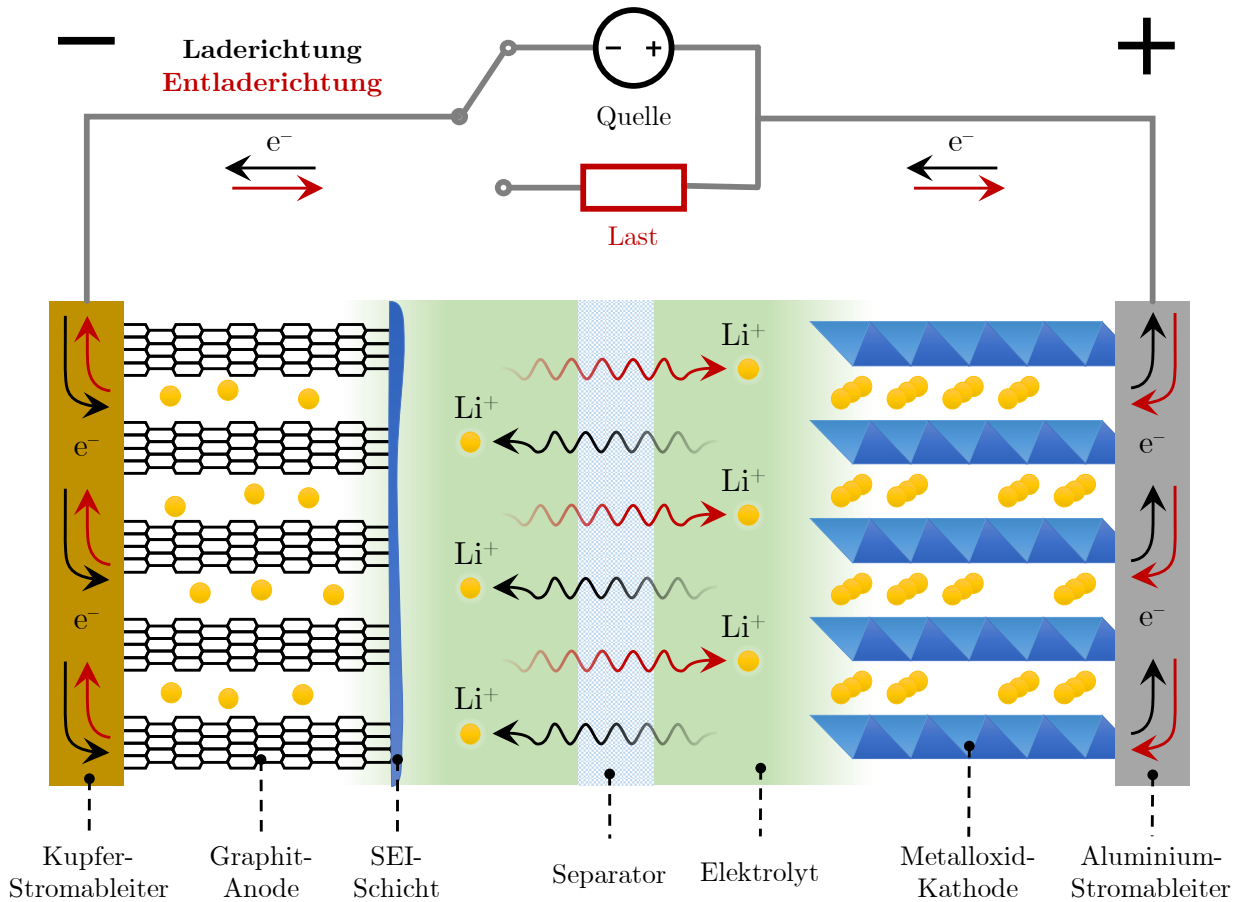
Die beiden Abschnitte 2.1.1 und 2.1.2, die den Aufbau, die Funktion und Definitionen einführen, basieren auf oder sind angelehnt an die grundlegende Literatur [4, 133, 149, 155].

#### 2.1.1 Aufbau und Funktion

Aufgrund der breiten Einsatzgebiete, sind Lithium-Ionen-Batterien in unterschiedlichsten Formaten und Zellchemien kommerziell verfügbar und industriell im Einsatz. Das grundlegende Funktionsprinzip ist jedoch vergleichbar.

Lithium ist im Periodensystem der Elemente das Metall mit der geringsten molaren Masse von 7 g/mol. Das Metall besitzt zudem ein sehr hohes negatives elektrochemisches Potential von  $E^0 = -3.045$  V gegenüber der Standardwasserstoffelektrode. Aufgrund dieser Eigenschaften ist Lithium prädestiniert für den Einsatz in elektrochemischen Energiespeichern, da es Batterien mit einer sehr hohen Energie- und Leistungsdichte ermöglicht.

Abbildung 2.1 zeigt schematisch den prinzipiellen Aufbau und die Funktionsweise einer Lithium-Ionen-Zelle während des Lade- und Entladevorgangs. Lithium-Ionen-Batterien bestehen allgemein aus einer porösen negativen Elektrode, der Anode, und einer porösen positiven



**Abbildung 2.1:** Prinzipieller Aufbau und Funktionsweise einer Lithium-Ionen-Zelle (angelehnt an [109]).

Elektrode, der Kathode. Beide Elektroden befinden sich in einem ionenleitfähigen Elektrolyten und werden durch einen Separator getrennt. Der isolierende Separator ist für Ionen durchlässig, aber für Elektronen unpassierbar. Metallische Stromableiter an den Elektroden ermöglichen eine niederimpedante elektrische Verbindung zu den Zellterminals.

Das aktive Element der Zelle ist Lithium, welches aufgrund einer externen Quelle (Laden) oder Last (Entladen) zwischen den Elektroden hin und her transportiert wird. Beim Laden werden die Lithium-Ionen  $Li^+$  der positiven Elektrode, durch den Elektrolyten und den Separator zur negativen Elektrode transportiert. An der Anode rekombinieren die Lithium-Ionen  $Li^+$  mit den von außen bereitgestellten Elektronen zu neutralem Lithium Li, welche in das Kohlenstoffgitter der negativen Elektrode interkaliert werden. Dieser Prozess kehrt sich beim Entladen um. Lithium-Ionen  $Li^+$  wandern durch den Elektrolyten zur positiven Elektrode wo sie in die Kristallstruktur der Kathode eingebaut werden.

### Eingesetzte Materialien

Die Anforderungen an die Aktivmaterialien, die an den Elektroden eingesetzt werden, sind eine möglichst hohe Potentialdifferenz zwischen Anode und Kathode sowie eine hohe spezifische

Kapazität. Weitere Randbedingungen die dabei zu berücksichtigen sind, sind die Reversibilität der Lithium-Speicherung, die Stabilität der Materialien, die elektrische und ionische Leitfähigkeit, die Umweltverträglichkeit, die Sicherheit und der Preis sowie die Verfügbarkeit der benötigten Rohstoffe [133]. Je nach Zusammensetzung der Elektrodenmaterialien und der Kombination von Anode und Kathode ergeben sich unterschiedlichste Zellentypen mit verschiedenen Eigenschaften.

Mögliche Anodenmaterialien sind Lithium-Metalle oder -Legierungen, amorpher Kohlenstoff oder Graphit. Heutige Technologien verwenden für die negative Elektrode meist Graphit. Im Vergleich zu amorphem Kohlenstoff ermöglicht Graphit eine höhere Speicherkapazität für Lithium bei einem guten Sicherheitsverhalten. Wie in Abbildung 2.1 schematisch dargestellt, besitzen Graphit-Anoden eine wabenartige, planare Struktur. In dieser hexagonalen Gitterstruktur dominieren Van-der-Waals-Kräfte, die die Graphitschichten zusammenhalten, aber auch eine Einlagerung von Lithium-Ionen zwischen den Graphitschichten ermöglichen. Die Maximalbelegung der Anode entspricht einem Lithium Atom je sechs Kohlenstoffatomen.

Während sich als Anodenmaterial Graphit weitgehend durchgesetzt hat, variieren die Kathodenmaterialien heute immer noch signifikant. Das am meisten erforschte und anfangs eingesetzte Material ist Lithium-Cobaltoxid (LCO). Da jedoch Cobaltoxid in Bezug auf Sicherheit, Kosten, Verfügbarkeit und der Umweltverträglichkeit des Abbaus kritisch zu bewerten ist, haben sich für breit eingesetzte Zellen andere Zellchemien durchgesetzt. Dazu gehören Lithium-Eisenphosphat (LFP) und Lithium-Nickel-Mangan-Cobaltoxid (NMC). LFP ermöglicht Cobalt-freie Zellen, niedrige Rohmaterialkosten und überzeugt durch eine gute Stabilität sowie der damit einhergehenden Sicherheit. Da NMC jedoch eine höhere Spannung ermöglicht und mehr Flexibilität im Zelldesign bietet, zählt es heute trotz des vorhandenen Cobalt-Anteils zu den erfolgreichsten Materialien. Je nach Mischverhältnis lassen sich Zellen mit höherer Energie- oder höherer Leistungsdichte entwickeln. Nickel begünstigt eine hohe Energiedichte während Mangan für niedrige Innenwiderstände sorgt, was für eine hohe Leistungsdichte entscheidend ist. Auch in Bezug auf Langlebigkeit, Sicherheit und Kosten bildet die NMC-basierte Zellchemie einen sinnvollen Kompromiss.

Bei den Stromableitern handelt es sich um dünne Metallfolien oder Metallgitter. Entscheidend bei der Wahl des Materials ist die elektrochemische Stabilität für das Potential der jeweiligen Elektrode. Als Anodenableiter wird Kupfer aufgrund seiner guten Leitfähigkeit eingesetzt. Kupfer ist jedoch beim Potential der Kathode nicht stabil, was zu starker Korrosion führen würde. Aus diesem Grund kommt an der Kathode meist Aluminium zum Einsatz. Aluminium ist beim Kathodenpotential stabil und zudem leichter als Kupfer, besitzt jedoch eine deutlich geringere Leitfähigkeit.

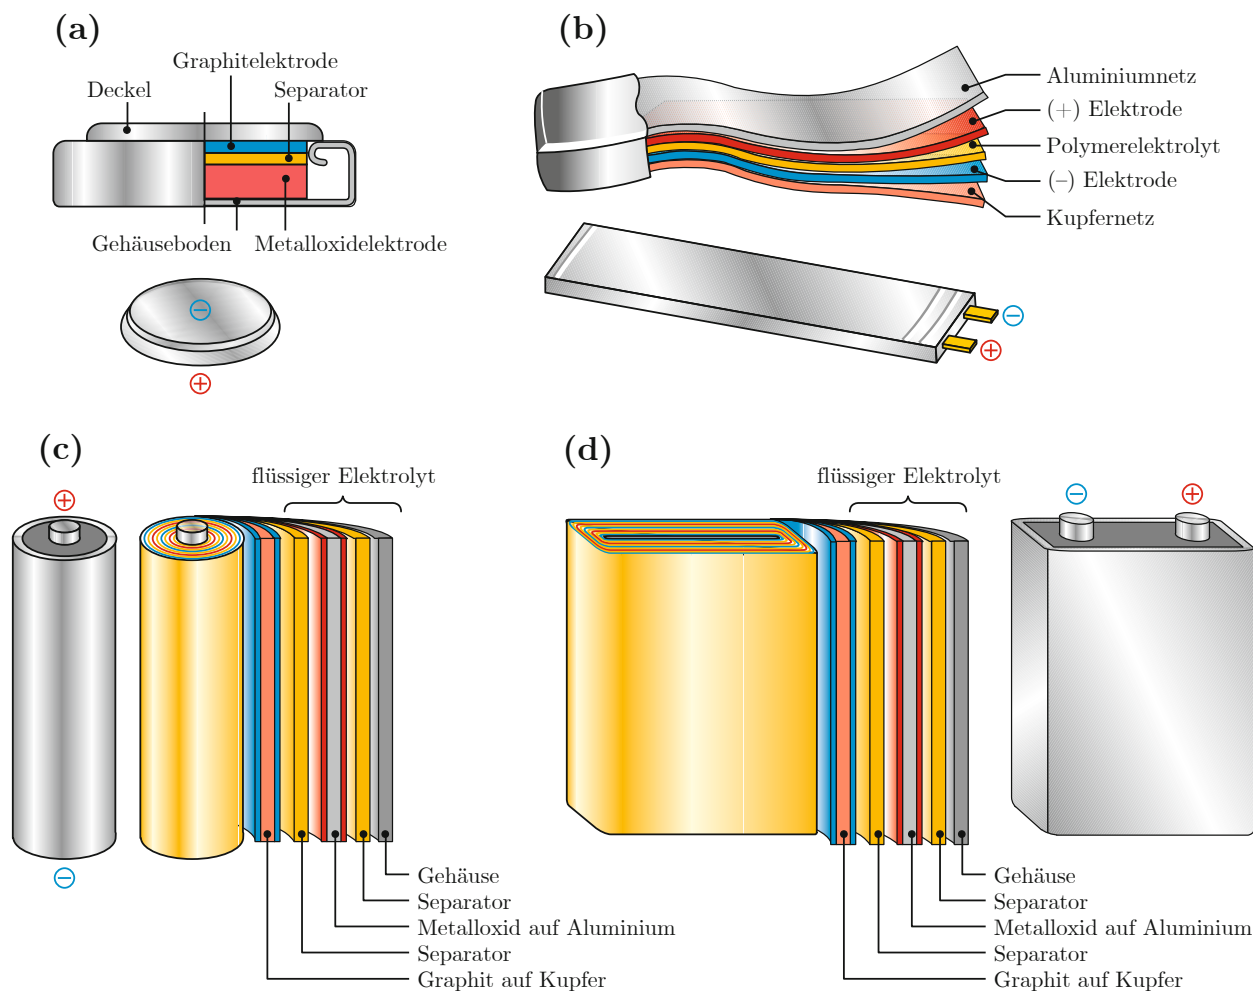
Die Elektroden trennt der Separator, eine poröse Membran aus Polyethylen oder Polypropylen. Die Anforderungen an den Separator sind neben mechanischer und chemischer Stabilität elektrisch isolierende Eigenschaften sowie eine hohe Ionenleitfähigkeit. Um letztere zu erreichen, ist der Separator mit dem Elektrolyten durchtränkt. Ein möglichst dünner Separator

begünstigt zudem einen geringen Innenwiderstand und eine mit der höheren Packungsdichte einhergehenden Energiedichte.

Der den Separator umgebende Elektrolyt ermöglicht einen Ionenfluss zwischen beiden Elektroden. Die ionische Leitfähigkeit wird durch Leitsalze im Elektrolyten erreicht. Durch die Zugabe weiterer Additive lässt sich die Viskosität und die Leitfähigkeit steuern. Zudem besitzt der Elektrolyt Additive, die den Aufbau von Deckschichten an den Grenzflächen steuern und ihre Eigenschaften beeinflussen. Zu der wichtigsten Grenzfläche gehört die Schicht zwischen der Anode und dem Elektrolyten, an der sich im ersten Zyklus, der Formierung, der Batterie die Solid-Electrolyte-Interphase-Schicht (SEI-Schicht) ausbildet (siehe Abbildung 2.1). Für eine hohe Lebensdauer sollte der Elektrolyt so entwickelt sein, dass sich eine stabile SEI-Schicht ausbildet, die zudem eine möglichst hohe Ionenleitfähigkeit besitzen sollte.

## Bauformen

Um eine große aktive Fläche nach dem in Abbildung 2.1 dargestellten Prinzip zu erreichen, erfolgt in der Anwendung eine Stapelung oder Wicklung des Aufbaus. Basierend darauf haben sich die in Abbildung 2.2 gezeigten Zellformate etabliert. Aufgrund ihrer kleinen Bauform und der damit einhergehenden geringen Kapazität sind Knopfzellen (Abbildung 2.2a) vor allem in kleineren elektronischen Geräten, wie Armbanduhren oder Kopfhörern verbreitet. Aufgrund ihres hohen Gehäuseanteils sind sie als Traktionsbatterien von Elektrofahrzeugen ungeeignet. Das in Abbildung 2.2b dargestellte Pouch-Format besitzt im Unterschied zu den übrigen Bauformen kein hartes Gehäuse. Sie decken ein weites Feld an Baugrößen und Kapazitäten ab. Pouch-Batterien sind in der Regel gestapelt aufgebaut, was sowohl auf Zell- als auch Systemebene eine hohe Energiedichte ermöglicht. Durch ihre weiche Einhausung ist die Volumenänderung bei einer Ladezustandsänderung besonders ausgeprägt. Durch Wicklung der aktiven Fläche ergibt sich auf natürliche Weise ein zylindrischer Körper, woraus zusammen mit einem zylindrischen, harten Gehäuse das zylindrische Zellformat resultiert (Abbildung 2.2c). Vor allem in der Bauform 18650 (18 mm Durchmesser, 650 mm Höhe) ist dieses Zellformat sehr weit verbreitet. Auf Systemebene verringert sich die Energiedichte jedoch aufgrund der kreisförmigen Grundflächen. Unter anderem aus diesem Grund verbreitet sich in letzter Zeit die Bauform 21700 (21 mm Durchmesser, 700 mm Höhe) zunehmend, da sie eine höhere Energiedichte auf Systemebene ermöglicht. Während zylindrische Zellen vor allem in kleineren Bauformen zu finden sind, werden prismatische Zellen (Abbildung 2.2d) vor allem für größere Zellformate (bis in den dreistelligen Ah-Bereich) eingesetzt. Das Zellgehäuse beinhaltet wie in Abbildung 2.2d dargestellt einen Flachwickel oder einen gestapelten Aufbau. Aufgrund der prismatischen Bauform ist die Energiedichte auf Zellebene im Vergleich zu den anderen Bauformen geringer, steigt jedoch mit zunehmender Zellgröße an. Da prismatische Zellen auf Systemebene eine hohe Energiedichte erzielen, kommen sie häufig als Traktionsbatterien in BEVs oder HEVs zum Einsatz.



**Abbildung 2.2:** Bauformen und Zellformate von Lithium-Ionen-Batterien: (a) Knopfzelle, (b) Pouch-Zelle, (c) zylindrische Zelle, (d) prismatische Zelle. Aus [155] mit Genehmigung von *Springer Nature*.

### 2.1.2 Wichtige Begriffe und Definitionen

Für den Umgang mit Lithium-Ionen-Zellen und Batteriesystemen hat sich eine Reihe von wichtigen Begriffen und Definitionen etabliert, die nachfolgend eingeführt werden.

**Nennkapazität** Bei der Nennkapazität handelt es sich um die vom Hersteller angegebene Kapazität, meist in der Einheit Ah. Sie beschreibt die Menge an elektrischer Ladung  $Q_{\text{nenn}}$ , die aus einer vollständig geladenen Batteriezelle unter Nennbedingungen entnommen werden kann:

$$Q_{\text{nenn}} = - \int_0^{t_{\text{co}}} I_{\text{nenn}} d\tau \Big|_{I_{\text{nenn}}=\text{const.}} = -I_{\text{nenn}} t_{\text{co}}. \quad (2.1)$$

Das Testverfahren zur Bestimmung der Nennkapazität spezifiziert der Hersteller selbst. In der Regel wird die Batterie bei einer definierten Temperatur mit einem konstanten Strom  $I_{\text{nenn}}$  entladen. Das negative Vorzeichen resultiert aus der Konvention, dass Entladeströme negativ sind. Die Größe  $t_{\text{co}}$  entspricht dem Zeitpunkt zu dem die Zelle ihre untere Cut-Off-Spannung

erreicht.

**Nutzbare Kapazität** Die nutzbare Kapazität  $Q$  beschreibt die tatsächlich entnehmbare Ladungsmenge aus einer Batteriezelle. Sie wird nach dem gleichen Prinzip wie die Nennkapazität ermittelt. Die Spezifikationen des Kapazitätstests im Rahmen der vorliegenden Arbeit gibt Abschnitt 2.2.1. Die nutzbare Kapazität hängt von der Stromrate, der Temperatur, der Cut-Off-Spannung und dem Alterungszustand der Batterie ab. Bei neuen Batterien, einer geringen Stromrate oder einer erhöhten Temperatur übersteigt die nutzbare Kapazität in der Regel die Nennkapazität. Besonders mit zunehmendem Alter kann sich jedoch die nutzbare Kapazität einer Batterie irreversibel verringern.

**C-Rate** Zur Berechnung der C-Rate wird der Lade- oder Entladestrom mit der Zellkapazität normiert. Sie trägt zur Vergleichbarkeit der Strombelastung von Batteriezellen unterschiedlicher Größe bei. Die vollständige Entladung einer vollgeladenen Batterie mit einer C-Rate von 1 C dauert, abhängig von der tatsächlich nutzbaren Kapazität, etwa 1 h. Die Normierung erfolgt in dieser Arbeit stets mit der Nennkapazität  $Q_{\text{nenn}}$ , auch wenn gerade die Kapazität  $Q$  gealterter Zellen davon abweicht. Dies hat zur Folge, dass die 1 C-Entladung neuer Zellen länger als 1 h dauern kann und bei niedrigen Temperaturen oder gealterten Zellen 1 h unterschreitet. Diese Konvention erweist sich jedoch aufgrund einer hohen Reproduzierbarkeit und Vergleichbarkeit als vorteilhaft.

**Entladetiefe** Die Entladetiefe (Depth-Of-Discharge, DOD)

$$\text{DOD}(t) = \int_0^t I(\tau) d\tau \quad (2.2)$$

zum Zeitpunkt  $t$  entspricht der aktuell entnommenen Ladung der Batterie, nach Anregung mit einem Stromprofil  $I(\tau)$ ,  $\tau \in [0, t]$ . Im vollgeladenen Zustand beträgt die Entladetiefe  $\text{DOD}(t) = 0$  Ah. Eine vollständig entladene Zelle besitzt eine Entladetiefe von  $\text{DOD}(t) = -Q$ .

**Ladezustand** Der Ladezustand (State-Of-Charge, SOC)

$$\text{SOC}(t) = 1 - \frac{1}{Q_{\text{nenn}}} \int_0^t I(\tau) d\tau = 1 - \frac{\text{DOD}(t)}{Q_{\text{nenn}}} \quad (2.3)$$

entspricht dem Anteil der Zellkapazität, der zum Zeitpunkt  $t$  noch entnommen werden kann. Da die tatsächlich nutzbare Kapazität, wie oben beschrieben, während des Betriebs variiert, ist die Konvention dieser Arbeit eine Normierung mit der Nennkapazität  $Q_{\text{nenn}}$ . Auch hier besteht der Vorteil in der Vergleichbarkeit und einer einfachen Umrechenbarkeit von DOD und SOC, da  $Q_{\text{nenn}}$  eine Konstante ist. Allerdings kann die konstante Normierung im Falle neuer Zellen oder einer Belastung mit geringen Stromraten in einem negativen SOC resultieren.

Umgekehrt erreichen gealterte Zellen ihre untere Cut-Off-Spannung bereits, bevor der SOC bei 0 % ist. Dennoch erweist sich diese Konvention als vorteilhaft.

**Zyklische und kalendarische Alterung** Zyklische Alterung resultiert aus dem gesamten Ladungsdurchsatz einer Zelle. Durch Normierung mit der doppelten Nennkapazität  $2 \cdot Q_{\text{nenn}}$  erhält man die Anzahl der Zyklen

$$N_{\text{cyc}} = \frac{1}{2 \cdot Q_{\text{nenn}}} \int_0^t |I(\tau)| d\tau, \quad (2.4)$$

die eine Kennzahl für die zyklische Alterung ist. Eine vollständige Entladung einer geladenen Zelle und eine anschließende Ladung entspricht also genau einem Zyklus.

Das kalendarische Alter einer Zelle entspricht der Zeitdauer seit Herstellung der Zelle, unabhängig vom tatsächlichen Einsatz der Batterie.

**Gesundheitszustand** Mit zunehmender zyklischer und kalendarischer Alterung zeigen Lithium-Ionen-Zellen eine sinkende Kapazität und meist einen Anstieg ihres Innenwiderstands. Aufgrund der Vielzahl an Alterungseffekten erfolgt der Kapazitätsverlust und der Widerstandszuwachs jedoch oft nicht monoton. Der Gesundheits- oder Alterungszustand (State-Of-Health, SOH) einer Zelle bezeichnet den Anteil

$$\text{SOH} = \frac{Q}{Q_{\text{nenn}}} \quad (2.5)$$

der noch verbleibenden, nutzbaren Kapazität  $Q$  an der initialen Nennkapazität  $Q_{\text{nenn}}$ . Basierend darauf lässt sich der Kapazitätsverlust

$$\text{SOH}_Q = \frac{Q_{\text{nenn}} - Q}{Q_{\text{nenn}}} = 1 - \text{SOH} \quad (2.6)$$

und analog dazu der Widerstandszuwachs

$$\text{SOH}_R = \frac{R - R_{\text{nenn}}}{R_{\text{nenn}}} \quad (2.7)$$

ermitteln, wobei  $R_{\text{nenn}}$  der initial ermittelte Innenwiderstand der Zelle ist [41].

**Ladeverfahren** Die Ladung von Lithium-Ionen-Zellen beginnt in der Regel mit einer konstanten C-Rate, was als Konstantstrom-Phase oder Constant-Current-Phase (CC-Phase) bezeichnet wird. Sobald die Zelle ihre obere Cut-Off-Spannung erreicht hat, hält das Ladegerät die Spannung an den Zellterminals konstant, was als Konstantspannungs-Phase oder Constant-Voltage-Phase (CV-Phase) bezeichnet wird. Um die Spannung konstant zu halten liefert die Quelle einen annähernd exponentiell abfallenden Ladestrom. Sobald der Strom unter einen

definierten Schwellwert gefallen ist, endet die Ladephase und die Batterie gilt als vollständig geladen. Das gesamte Prozedere wird als CCCV-Ladung bezeichnet.

Um einen definierten vollgeladenen Zustand ( $DOD = 0$  Ah beziehungsweise  $SOC = 100\%$ ) zu erhalten, muss die CCCV-Ladung neben einem definierten Strom-Schwellwert auch bei einer definierten Temperatur erfolgen.

**Balancieren** Auch wenn Batteriesysteme meist aus möglichst homogenen Zellen bestehen, ist es in der Praxis nicht möglich, identische Zellen zu produzieren. In Batteriesystemen äußern sich Parametervariationen wie Kapazitäts- oder Widerstandsunterschiede beispielsweise in einer inhomogenen Strom- und Temperaturverteilung. Daraus resultieren geringe Unterschiede im Ladezustand, die sich jedoch mit der Zeit kumulieren. Während sich der Ladezustand parallelverschalteter Zellen spannungsbasiert ausgleicht, erfordern seriell verschaltete Zellen ein Balancieren, nachfolgend *Balancing* genannt. Auch wenn jedem parallelen Zellverbund aufgrund der übergeordneten Serienschaltung jeweils die gleiche Ladungsmenge beim Laden zugeführt und beim Entladen entnommen wird, entstehen insbesondere durch Unterschiede in der Selbstentladungsrate oder in der Coulombschen Effizienz Diskrepanzen, die eine Balancing-Vorrichtung ausgleichen muss [65]. Unterscheiden lassen sich dabei passive Balancing-Verfahren, die die zusätzliche Energie starker Zellen dissipieren und aktive Balancing-Verfahren, bei denen die zusätzliche Ladung starker Zellen auf die übrigen Zellen umverteilt wird.

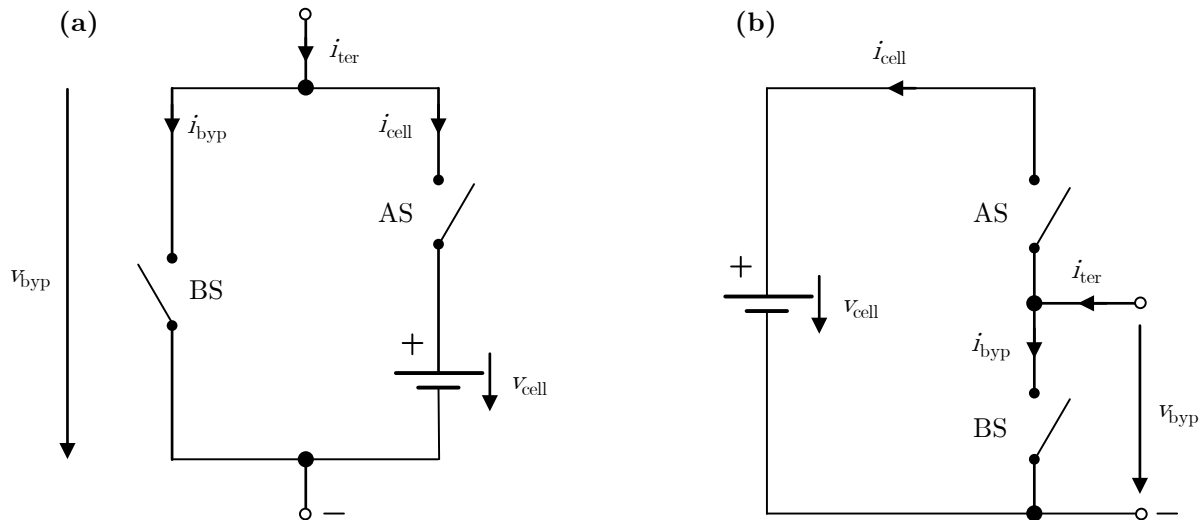
### 2.1.3 Batteriemanagement und rekonfigurierbare Batteriesysteme

Um den Reichweiten- und Leistungsanforderungen von BEVs und HEVs gerecht zu werden, besitzen Traktionsbatterien eine Vielzahl an Einzelzellen, die parallel und seriell verschaltet sind. Eine Parallelschaltung senkt den Widerstand, erhöht die maximal zulässigen Ströme und die Kapazität. Die Serienschaltung erhöht die Betriebsspannung und die Kapazität. Die Anzahl  $X$  der seriellen und  $Y$  der parallelen Zellen fasst die Notation  $XsYp$  zusammen.

Um einen sicheren Betrieb aller Zellen innerhalb des zulässigen Betriebsbereichs zu gewährleisten, überwacht ein BMS die Spannungen, Ströme und Temperaturen der Zellen. BMSs auf dem Stand der Technik besitzen dafür einen Spannungssensor je Parallelverbund, messen den Gesamtstrom, der in  $Xs1p$ -Systemen direkt dem Zellstrom entspricht, und besitzen mehrere Temperatursensoren, die die Temperatur an kritischen Punkten erfassen [178, 260]. Eine weitere grundlegende Aufgabe des BMSs ist das Balancing der Zellen. Während parallele Zellen selbstbalancierend sind, erfordern serielle Zellen ein Balancing, um Parameterunterschiede auszugleichen [178].

Im Unterschied zu konventionellen Batteriesystemen mit einem herkömmlichen BMS besitzen IBS ein verteiltes BMS. Neben einer zentralen Recheneinheit verfügt jede Zelle über individuelle Spannungs-, Strom- und Temperatursensorik sowie eine eigene Recheneinheit.





**Abbildung 2.3:** Rekonfigurierbare Batteriezelle in normaler Darstellung (a) und in Halbbrückendarstellung (b) (angelehnt an [107]).

Die Kombination mit der Möglichkeit zur Rekonfiguration erlaubt zudem, den Stromfluss auf Zellebene zu kontrollieren. Dies ermöglicht ein kontinuierliches, aktives Balancieren der Zellen in Bezug auf den Ladezustand und den Alterungszustand sowie einen energieeffizienten Betrieb [19, 20, 21]. Im Falle von Störungen ermöglichen RBS die Überbrückung fehlerhafter Zellen, um eine Fehlertoleranz (*Bad-Block-Management*) zu erreichen [238]. Darüber hinaus eignen sich RBS für einen Einsatz als Hybridspeicher durch hochfrequentes Schalten [331]. RBS eignen sich auch zur Erzeugung einer Sinusspannung, indem Zellen sequentiell überbrückt oder dem Strompfad zugeschaltet werden. Eine weitere Anwendung ist daher die Drehstrombatterie in Form eines modularen Multilevel-Umrichters, die sich vorteilhaft mit dem Bad-Block-Management kombinieren lässt [46, 47, 115, 226].

Abhängig von der verwendeten Topologie erlauben RBS die Veränderung der Verschaltung auf Zellebene und passen die gesamte Batterie aktiv an, um den unterschiedlichen Zellcharakteristiken gerecht zu werden. In der Literatur ist eine Vielzahl unterschiedlicher Topologien bekannt. Eine Übersicht bieten [37, 146, 331]. Während einige Ansätze die Zellen auf Modulebene rekonfigurieren, bietet sich für IBS vor allem die in Abbildung 2.3 gezeigte Topologie mit zwei Schaltern je Zelle an, was einer Halbbrücke entspricht [107]. Mit dem Aktivschalter lässt sich die Zelle reversibel vom Leistungspfad trennen. Der Bypass-Schalter ermöglicht eine Überbrückung der Zelle, um im System den Leistungspfad zu schließen. Der Zustand, bei dem beide Schalter geschlossen sind, muss verhindert werden, um einen Kurzschluss der Zelle zu vermeiden. Zudem gilt für parallel geschaltete Zellen, dass alle Aktiv-Schalter geöffnet sein müssen, wenn eine Zelle überbrückt wird.

Die gewählte Topologie wird dem verteilten Ansatz von IBS gerecht und bietet darüber hinaus die Möglichkeit, elektrisch eigensichere Zellen mit spannungsfreien Terminals zu realisieren. In einer industriellen Anwendung wäre es auch denkbar, nur einen Bypass-Schalter

**Tabelle 2.1:** Spezifikationen der für die experimentellen Untersuchungen verwendeten Lithium-Ionen-Batteriezellentypen.

	PAN	SMG
Bezeichnung	Panasonic UF261591	Samsung INR18650-25R
Hersteller	Sanyo Panasonic	Samsung SDI
Zellformat	prismatisch	zylindrisch (18650)
Zellchemie	NMC/Graphit	NMC/Graphit
Nominelle Kapazität	25 Ah	2.5 Ah
Nominelle Spannung	3.7 V	3.6 V

für parallel geschaltete Zellen zu verwenden, da diese Topologie die gleiche Funktionalität bieten würde. Es ist jedoch zu beachten, dass der Bypass-Schalter dann in der Lage sein muss, den Gesamtstrom des Batteriesystems zu tragen, auch in thermischer Hinsicht. Erfordert dies eine Parallelschaltung mehrerer Schalter, reduziert sich die Bauteileinsparung, beziehungsweise ist nicht vorhanden. Dazu kommt der Vorteil des modularen Aufbaus der Zwei-Schalter-Lösung, der beispielsweise auch elektrisch eigensichere Zellen erlaubt.


## 2.2 Charakterisierung von Lithium-Ionen-Batterien

Während Kapitel 3 detailliert auf die Modellbildung von Lithium-Ionen-Batterien eingeht, konzentriert sich dieser Abschnitt auf die Charakterisierung der Zellen. Dafür stellt Abschnitt 2.2.1 die beiden verwendeten Zelltypen vor, die diese Arbeit durchgängig für die experimentellen Untersuchungen einsetzt. In den Abschnitten 2.2.2 und 2.2.3 erfolgt dann exemplarisch anhand dieser beiden Zellentypen die Identifikation der für die Modelle relevanten Parameter. Dazu kommen Methoden aus dem Zeit- und Frequenzbereich zum Einsatz.

Die Arbeit verfolgt durchgehend die Konvention, dass Ladeströme ein positives und Entladeströme ein negatives Vorzeichen besitzen.

### 2.2.1 Verwendete Zellen für die experimentellen Untersuchungen

Die experimentellen Untersuchungen und Validierungen dieser Arbeit erfolgen durchgängig anhand von zwei Zelltypen. Die Spezifikationen der verwendeten Zellen fasst Tabelle 2.1 zusammen. Die prismatische *Panasonic UF261591* Batteriezelle (PAN) kommt üblicherweise in (Plug-in-)HEV- und BEV-Anwendungen zum Einsatz. Da die PAN-Zellen ein kalendarisches Alter von zehn Jahren aufweisen, eignen sie sich, um Methoden in Anwesenheit von Alterungseffekten zu validieren. Aufgrund ihrer ähnlichen Eigenschaften findet zudem die zylindrische *Samsung INR18650-25R* Batteriezelle (SMG) für die durchgeführten Untersuchungen Verwendung. Es handelt sich dabei um neue Zellen, von denen ein Teil für verschiedene Versuche zyklisch gealtert wird.



**Abbildung 2.4:** Kapazitätstest einer SMG-Zelle bei unterschiedlichen Temperaturen.

Zur Bestimmung der tatsächlichen Kapazität erfolgt eine Entladung der vollgeladenen Batterie mit einem definierten Konstantstrom (CC-Entladung). Die Integration über den Strom, bis die Zelle ihre untere Cut-Off-Spannung erreicht, liefert die Kapazität der Batteriezelle. Abbildung 2.4 zeigt einen typischen Kapazitätstest für die SMG-Zelle bei verschiedenen Temperaturen. Abbildung A.1 zeigt ergänzend den analogen Test für eine PAN-Zelle. Untereinander sind der Strom, die Spannung und die entnommene Ladungsmenge in Form der Entladetiefe (DOD) abgebildet. Da die CC-Entladung mit einer Rate von 1 C bezogen auf die nominelle Kapazität erfolgt und es sich um neue Zellen handelt, dauert die Entladung bei 25 °C etwa eine Stunde. Zu beobachten ist, dass sich die Entladedauer und, damit verbunden, die entnehmbare Ladungsmenge bei der niedrigeren Temperatur von 15 °C deutlich verringert. Zudem zeigt der im Anhang abgebildete Kapazitätstest zur gealterten PAN-Zelle, dass sich die entnehmbare Kapazität neben der Temperatur auch aufgrund des Alters verringert. Nach einer halbstündigen Pause erfolgt eine CCCV-Ladung mit einer konstanten Stromrate von 1 C, bis sie ihre obere Cut-Off-Spannung erreicht. Die anschließende CV-Phase terminiert, sobald der Strom unter den Schwellwert 0,1 C gefallen ist. Zu beobachten ist, dass sich die CV-Phase bei niedrigeren Temperaturen aufgrund des höheren Innenwiderstands und der trägeren Zelldynamik verlängert. Eine Modellierung der Zelle erfordert deshalb die Identifikation des statischen und des dynamischen Batterieverhaltens für verschiedene Ladezustände und Temperaturen.

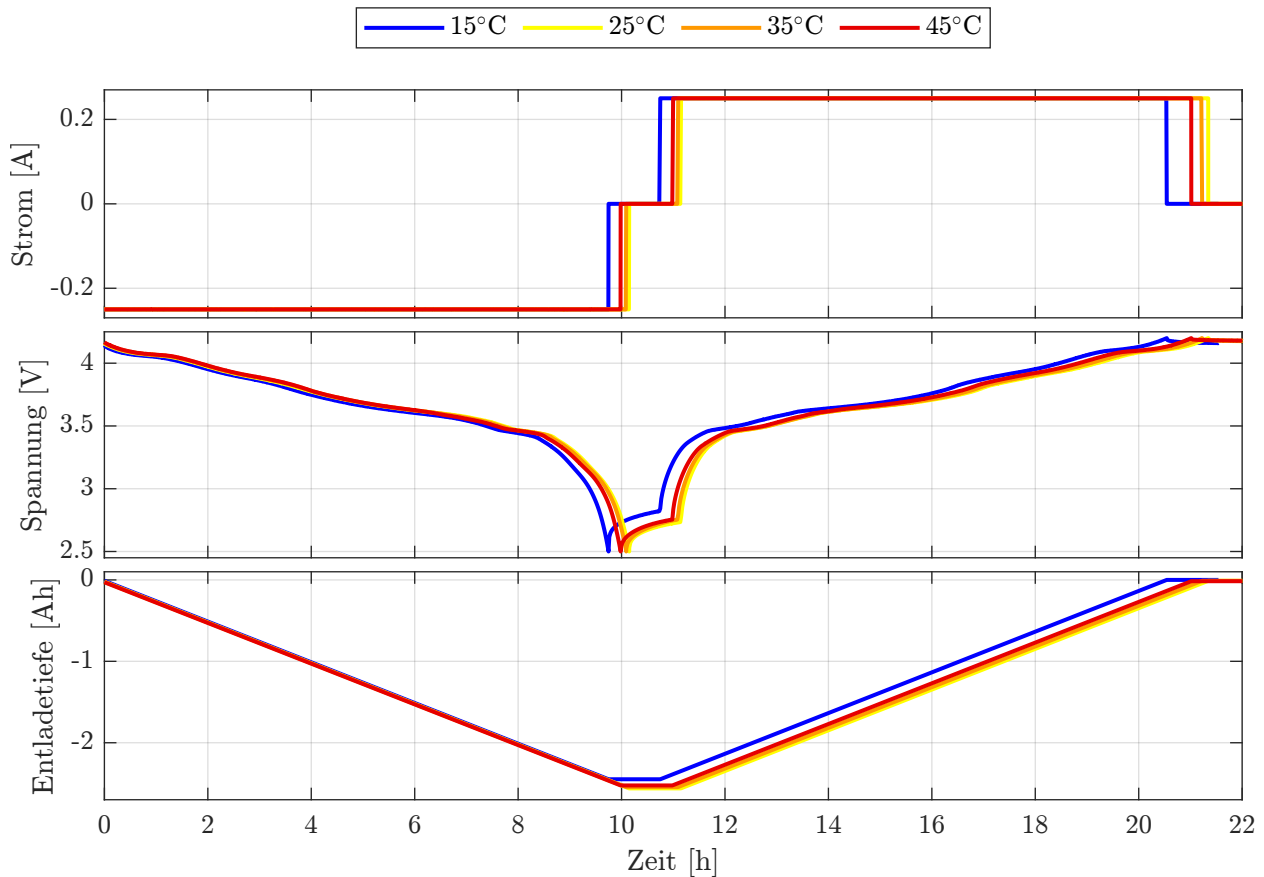


Abbildung 2.5: Test zur Ermittlung der POCV einer SMG-Zelle.

## 2.2.2 Identifikation des statischen Batterieverhaltens

Die Ruhe-, Gleichgewichts- oder Leerlaufspannung (Open-Circuit-Voltage, OCV) von Lithium-Ionen-Zellen hängt hauptsächlich vom Ladezustand ab. Für die meisten Zellchemien zeigt die Ruhespannung einen nichtlinearen, monotonen Zusammenhang mit dem Ladezustand [140]. Die Ruhespannung ist an den Zellklemmen messbar, sobald alle dynamischen Reaktionen abgeklungen sind. Je nach Zellchemie, Temperatur und Ladezustand der Zellen erfordert dies Wartezeiten von mehreren Stunden.

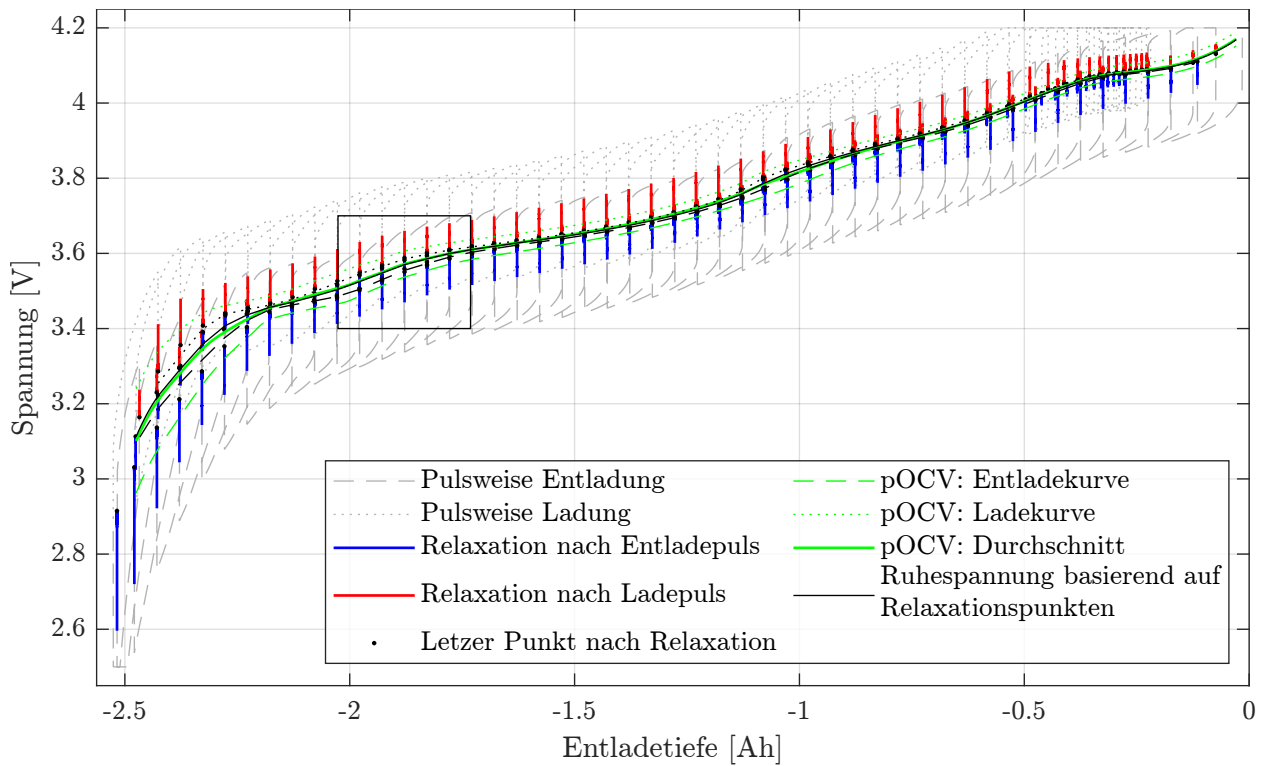
Um die Ruhespannungskennlinie für alle Ladezustände zu ermitteln existieren zwei gängige Verfahren: Die Pseudo-OCV-Methode (POCV-Methode) und die schrittweise Entladung der Zellen. Bei der POCV-Methode erfolgt eine CC-Entladung und anschließend eine CC-Ladung der Batteriezelle mit einem niedrigen Strom (siehe Abbildungen 2.5 und A.2). Der kleine Strom zielt darauf ab, das dynamische Verhalten der Zelle möglichst geringfügig anzuregen. Entsprechend steigt die Genauigkeit der Methode, je kleiner der Anregungsstrom gewählt wird. Die POCV-Methode nimmt die mittlere Spannung zwischen der Entladekurve und der Ladekurve als Ruhespannungskennlinie der Zelle an. Die Mittelung gleicht sowohl den Ohmschen Spannungsabfall als auch die dynamischen Polarisierungseffekte der Zelle in Lade und Entladerichtung aus. Ein Ausgleich resultiert jedoch nur, falls die Effekte in Lade- und

Entladerichtung tatsächlich symmetrisch sind. Zudem ergeben sich jeweils Abweichungen in den beiden extremen Ladezustandsbereichen, da sich die Zelle zu Beginn der Messung in Ruhe befindet (Fehler im hohen SOC-Bereich) und am Umkehrpunkt von Entladung zu Ladung (Fehler im niedrigen SOC-Bereich) eine Umpolarisierung stattfindet. Eine Pause zwischen der Entladung und Ladung (siehe Abbildung 2.5,  $t \in [10 \text{ h}, 10.5 \text{ h}]$ ) kann diesen Effekt verringern.


Als genauere Alternative zur kontinuierlichen Entladung der Zelle bietet sich eine schrittweise Entladung an. Nach jeder Entladung erfolgt eine mehrstündige Pause, bis sich der Gleichgewichtszustand in der Zelle einstellt. Analog erfolgt im Anschluss eine schrittweise Ladung der Zelle. Die Mittelung der Spannungen am Ende der Pause für den Entlade- und Entladefall liefern für verschiedene SOC-Stützstellen die Punkte der Ruhespannungskennlinie. Je genauer die nichtlineare Ruhespannungskennlinie approximiert werden soll, das heißt je mehr Stützstellen ausgewertet werden sollen, desto größer ist der Zeitaufwand. Während eine Ermittlung der POCV mit einer Stromrate von 0.1 C, wie in Abbildung 2.5 gezeigt, etwa 21 h dauert, beläuft sich die Ermittlung einer schrittweisen OCV bei 25 Stützstellen und 4 h Wartezeit auf  $2 \cdot 25 \cdot 4 \text{ h} = 200 \text{ h} \approx 8.3 \text{ d}$  [140].

Das im Rahmen dieser Arbeit entwickelte Verfahren zur Bestimmung der Ruhespannungskennlinie basiert ebenfalls auf der schrittweisen Ermittlung der OCV-Kennlinie. Dabei folgt jedoch jedem Entladepuls ein Ladepuls mit kleiner Amplitude. Umgekehrt folgt während der Ladephase jedem Ladepuls ein Entladepuls mit kleinerer Amplitude (siehe Abbildung 2.9). Dieser Test ermöglicht eine Ermittlung der Ruhespannungskennlinie mit 50 Stützstellen in etwa  $100 \text{ h} \approx 4.2 \text{ d}$ . Das Verfahren kombiniert zudem die für die Identifikation des dynamischen Verhaltens erforderliche Anregung mit der schrittweisen Bestimmung der OCV und lässt eine Ermittlung der Hysterese-Kennlinie aus den Messdaten zu.

Abbildung 2.6 zeigt die zur Zellcharakterisierung gemessenen Spannungen über der Entladetiefe aufgetragen. Die über das POCV-Verfahren ermittelte Kennlinie ist in Grün und die schrittweise ermittelte Kennlinie in Schwarz dargestellt. Die vollständigen, während der 100 h gemessenen Rohdaten zeigen die grau gestrichelten und gepunkteten Linien. Jede dynamische Anregung der Zelle verursacht eine Verschiebung der gemessenen Spannung gegenüber der Ruhespannung. Während die Entlade- und Ladekurve im Falle der POCV-Methode aufgrund der geringen Ströme bereits nahe an der tatsächlichen Ruhespannung liegen, sind bei der pulsweisen Entladung und Ladung größere Anregungen zu beobachten. Aus den letzten Messpunkten nach der Relaxation der Zellen lassen sich zwei Hilfskennlinien (schwarz gepunktet und schwarz gestrichelt) ermitteln, auf deren Basis die schrittweise Ruhespannungskennlinie ermittelt werden kann. Im vergrößerten Bereich zeigt sich eine Diskrepanz zwischen den Relaxationspunkten während der Entladephase und der Ladephase. Dieser Effekt resultiert aus einer Hysterese, die sich in Lade- beziehungsweise Entladerichtung einstellt.



(a) Vollständige Messung.



(b) Ausschnitt aus Abbildung 2.6a.

**Abbildung 2.6:** Vergleich der POCV-Methode und der schrittweisen Entladung zur Ermittlung der Ruhespannungskennlinie.

### 2.2.3 Identifikation des dynamischen Batterieverhaltens

Wie die Identifikation des statischen Batterieverhaltens zeigt, beeinflusst das dynamische Verhalten die Klemmenspannung der Zelle signifikant. Zur Identifikation des dynamischen Verhaltens sind im Batteriebereich sowohl Methoden aus dem Frequenzbereich als auch aus dem Zeitbereich üblich. Die Identifikation im Frequenzbereich wird als Elektrochemische Impedanzspektroskopie (EIS) bezeichnet. Die EIS regt die Batterie meist mit einem sinusförmigen Anregungssignal an und misst die Systemantwort. Es lassen sich dabei zwei Arten der Anregung unterscheiden. Die *potentiostatische Impedanzspektroskopie* gibt ein Spannungssignal vor und misst die resultierende Stromantwort der Zelle. Umgekehrt erfolgt die *galvanische Impedanzspektroskopie* durch Vorgabe eines Anregungsstroms und Messung der Spannungsantwort. Zur Ermittlung des Batterieverhaltens für unterschiedliche Strombelastungen ermöglicht die galvanostatische Impedanzspektroskopie zudem die Überlagerung des sinusförmigen Anregungsstroms mit unterschiedlich großen Gleichströmen [140].

Die Anwendung der EIS setzt ein lineares, zeitinvariantes System voraus. Wie bei der Identifikation des statischen Batterieverhaltens im vorangegangenen Abschnitt 2.2.2 zu beobachten war, zeigen Batterien bei der Änderung des Ladezustands jedoch eine nichtlineare Änderung der Spannung. Analog variiert auch das dynamische Verhalten mit dem Ladezustand und der Temperatur. Um die Voraussetzungen für ein lineares, zeitinvariantes System zu erfüllen, ist es deshalb zentral, den Ladezustand und die Temperatur möglichst geringfügig zu ändern, um die Linearität am jeweiligen Arbeitspunkt zu gewährleisten. Dies erreicht die lineare EIS durch die Wahl möglichst kleiner Anregungsamplituden, die jedoch nach unten durch die Präzision der verwendeten Sensorik limitiert sind.

Harmonische Wechsignale lassen sich durch rotierende Zeiger in der komplexen Zahlenebene darstellen. Für eine konstante Kreisfrequenz  $\omega = 2\pi f$  resultieren die komplexe Spannung

$$\underline{u} = \hat{u} \cdot [\cos(\omega t + \varphi_u) + j \sin(\omega t + \varphi_u)] = \hat{u} \cdot e^{j(\omega t + \varphi_u)} \quad (2.8)$$

und der komplexe Strom

$$\underline{i} = \hat{i} \cdot [\cos(\omega t + \varphi_i) + j \sin(\omega t + \varphi_i)] = \hat{i} \cdot e^{j(\omega t + \varphi_i)} \quad (2.9)$$

mit den zugehörigen Amplituden  $\hat{u}$  und  $\hat{i}$ . Die Phasenwinkel  $\varphi_u$  und  $\varphi_i$  kennzeichnen den Zeitpunkt des Nulldurchgangs von Spannung und Strom. Analog zum Ohmschen Gesetz resultiert der komplexe Wechselstromwiderstand, die Impedanz, aus dem Quotienten von komplexer Spannung und komplexem Strom:

$$\underline{Z} = \frac{\underline{u}}{\underline{i}} = \frac{\hat{u} \cdot e^{j(\omega t + \varphi_u)}}{\hat{i} \cdot e^{j(\omega t + \varphi_i)}} = \frac{\hat{u} \cdot e^{j\varphi_u}}{\hat{i} \cdot e^{j\varphi_i}} = \frac{\hat{u}}{\hat{i}} \cdot e^{j(\varphi_u - \varphi_i)} = |\underline{Z}| \cdot e^{j\angle \underline{Z}}. \quad (2.10)$$

Dabei entspricht  $|\underline{Z}| = \hat{u}/\hat{i}$  dem Betrag der Impedanz und  $\angle \underline{Z} = \varphi = \varphi_u - \varphi_i$  ihrer

Phase, woraus in Polarkoordinaten direkt Radius und Winkel resultieren. Für die kartesische Darstellung erfolgt eine Aufteilung des Wechselstromwiderstands in Real- und Imaginärteil:

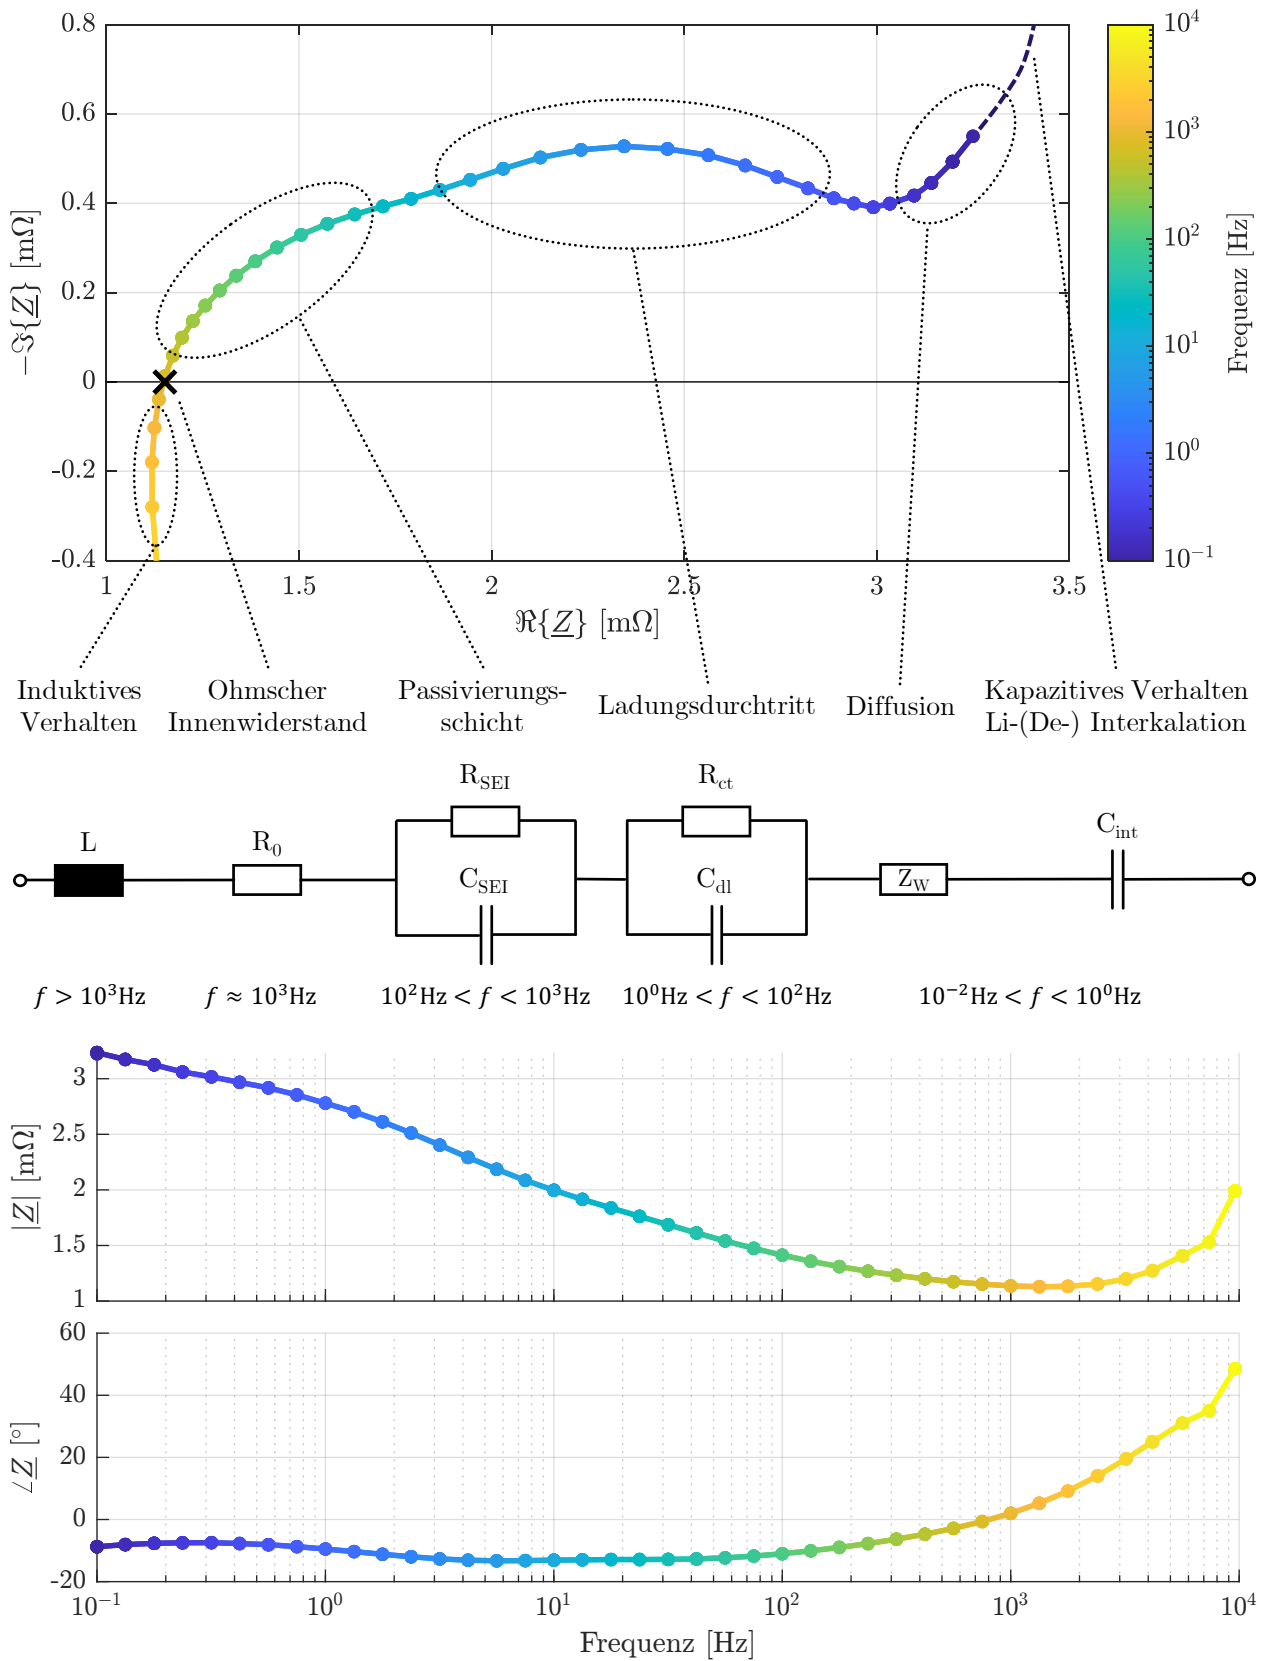
$$\underline{Z} = \Re\{\underline{Z}\} + j\Im\{\underline{Z}\} = \frac{\hat{u}}{\hat{i}} \cos(\varphi) + j \cdot \frac{\hat{u}}{\hat{i}} \sin(\varphi). \quad (2.11)$$

Zur Identifikation des dynamischen Zellverhaltens wird die Impedanz für verschiedene Anregungsfrequenzen ermittelt. Abbildung 2.7 (oben) zeigt den typischen Verlauf der Impedanz für eine Batteriezelle für eine Variation der Anregungsfrequenz von  $f \in [10^{-1}, 10^4]$  in Form eines Nyquist-Diagramms über Real- und Imaginärteil. Das Bode-Diagramm in Abbildung 2.7 (unten) zeigt als alternative Darstellung den Verlauf von Betrag und Phase über die Frequenz. Der Verlauf der Impedanz in Nyquist- und Bode-Diagramm ist charakteristisch für Batteriezellen. Obwohl die EIS nichtinvasiv ist, lässt sie Rückschlüsse auf zellinterne Effekte zu. Diese Effekte lassen sich je nach Anregungsfrequenz beobachten. So zeigen Batteriezellen bei sehr hohen Frequenzen ein induktives Verhalten, der Ohmsche Widerstand ist bei etwa  $f = 1$  kHz messbar, bei niedrigeren Frequenzen dominiert die Passivierungs- und Doppelschicht, worauf der Diffusionsbereich und, bei sehr niedrigen Frequenzen, ein kapazitives Verhalten folgt. Da für die Ermittlung der Impedanz für kleiner werdende Frequenzen jede Halbwelle der Sinusanregung eine größere Ladezustandsänderung verursacht und die Messungen zunehmend länger dauern, ist besonders dieser Bereich herausfordernd zu ermitteln. Abbildung 2.7 ordnet den beobachteten Effekten zudem ein elektrisches Ersatzschaltbild zu, das aus einer idealen Spule, einem Widerstand, RC-Elementen, der Warburg-Impedanz und einem idealen Kondensator besteht. Die von Warburg eingeführte Warburg-Impedanz ermöglicht die Abbildung eines  $45^\circ$ -Phasenwinkels in der komplexen Ebene [290].

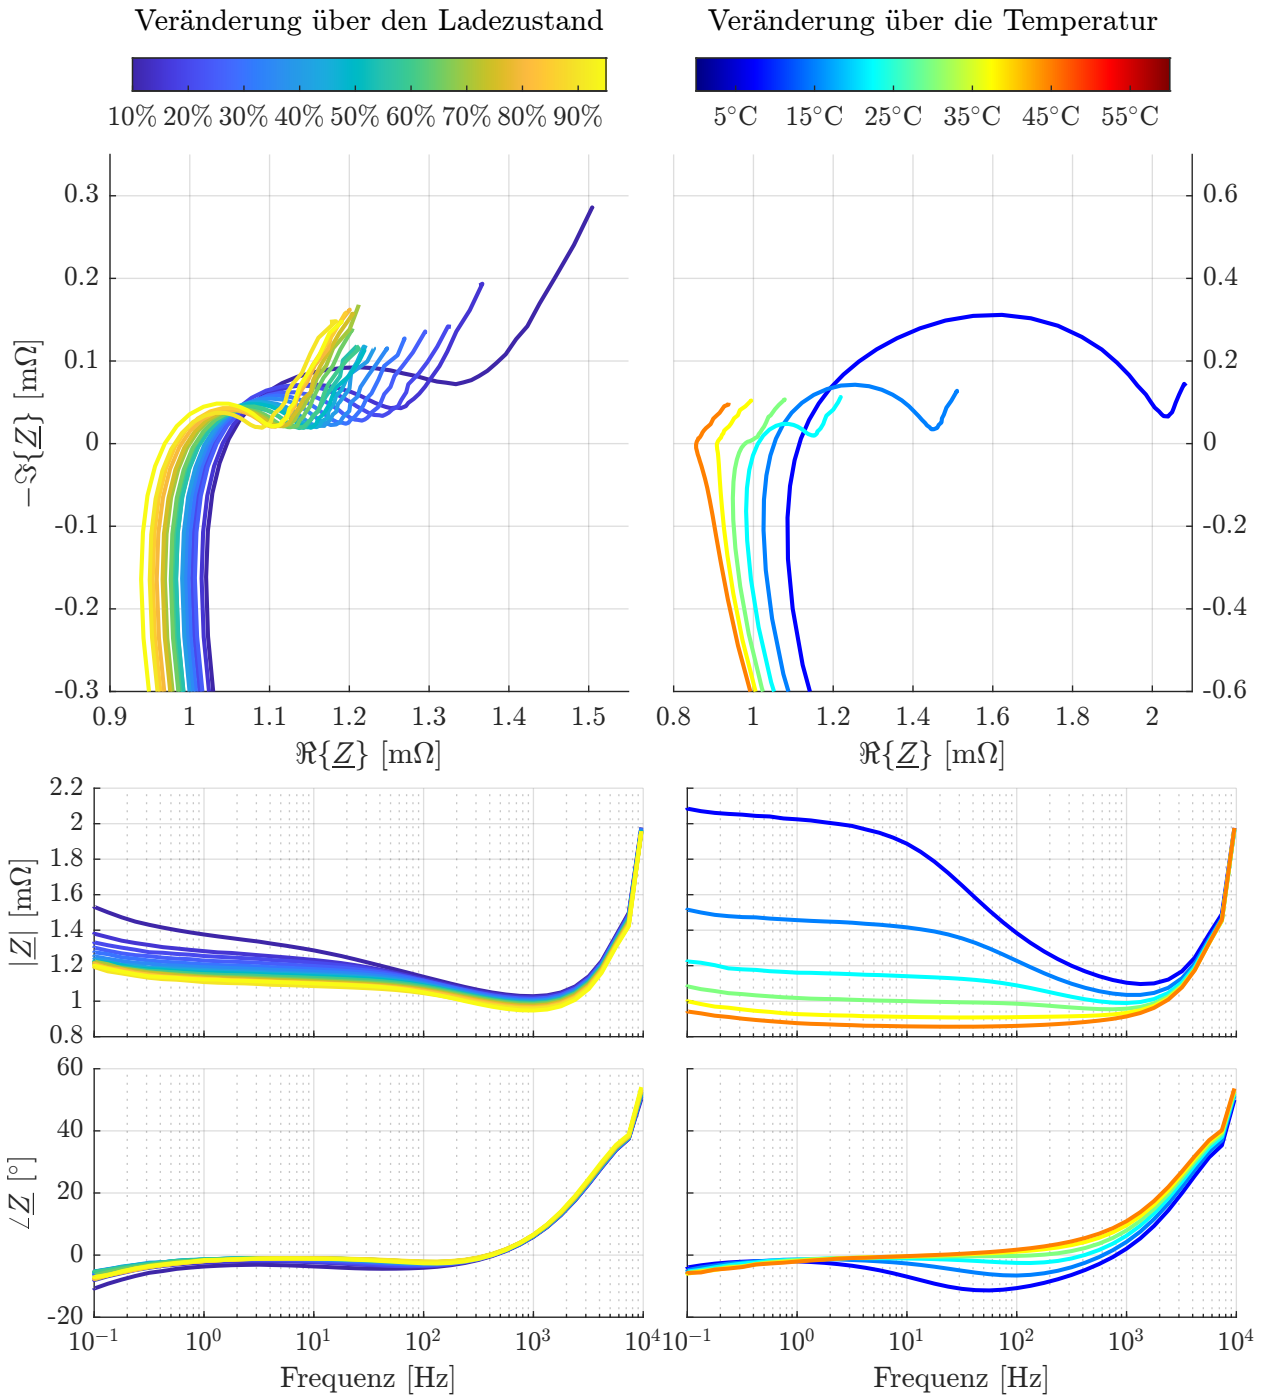
Je nach Zellchemie, Temperatur, Ladezustand oder Gleichstromanteil in der Messung unterscheidet sich das Impedanzspektrum der Zelle. Die beobachteten Effekte können unterschiedlich stark ausgeprägt sein oder bei anderen Frequenzen auftreten, sodass die Einzeleffekte, wie beispielsweise der Einfluss der SEI-Schicht und d: es Ladungsdurchtritts, verschmelzen und nicht separierbar sind. Exemplarisch zeigt Abbildung 2.8 die Änderung des Impedanzspektrums einer PAN-Zelle über den Ladezustand (links) und über die Temperatur (rechts). Sowohl über den Ladezustand als auch über die Temperatur ist eine signifikante Änderung des Batterieverhaltens zu beobachten. Generell ist für sinkende Ladezustände und sinkende Temperaturen eine Streckung und eine Verschiebung des Spektrums entlang der reellen Achse nach rechts zu beobachten, was mit einem ansteigenden Ohmschen Widerstand einhergeht. Die signifikante Änderung des Zellverhaltens über die verschiedenen Betriebsbereiche motiviert eine SOC- und Temperaturabhängige Parametrierung der Modelle.

Während sich die EIS besonders eignet, um die hochdynamischen Vorgänge im Bereich der Passivierungsschicht sowie des Ladungsdurchtritts oder der Doppelschichtkapazität zu untersuchen, ist die Untersuchung von Effekten mit höheren Zeitkonstanten, wie Diffusionseffekten, herausfordernder. Dies liegt daran, dass bei sinkender Frequenz jede Halbwelle der






**Abbildung 2.7:** Nyquist- und Bode-Diagramm einer PAN-Zelle bei einer Temperatur von 5 °C und einem Ladezustand von 10 %



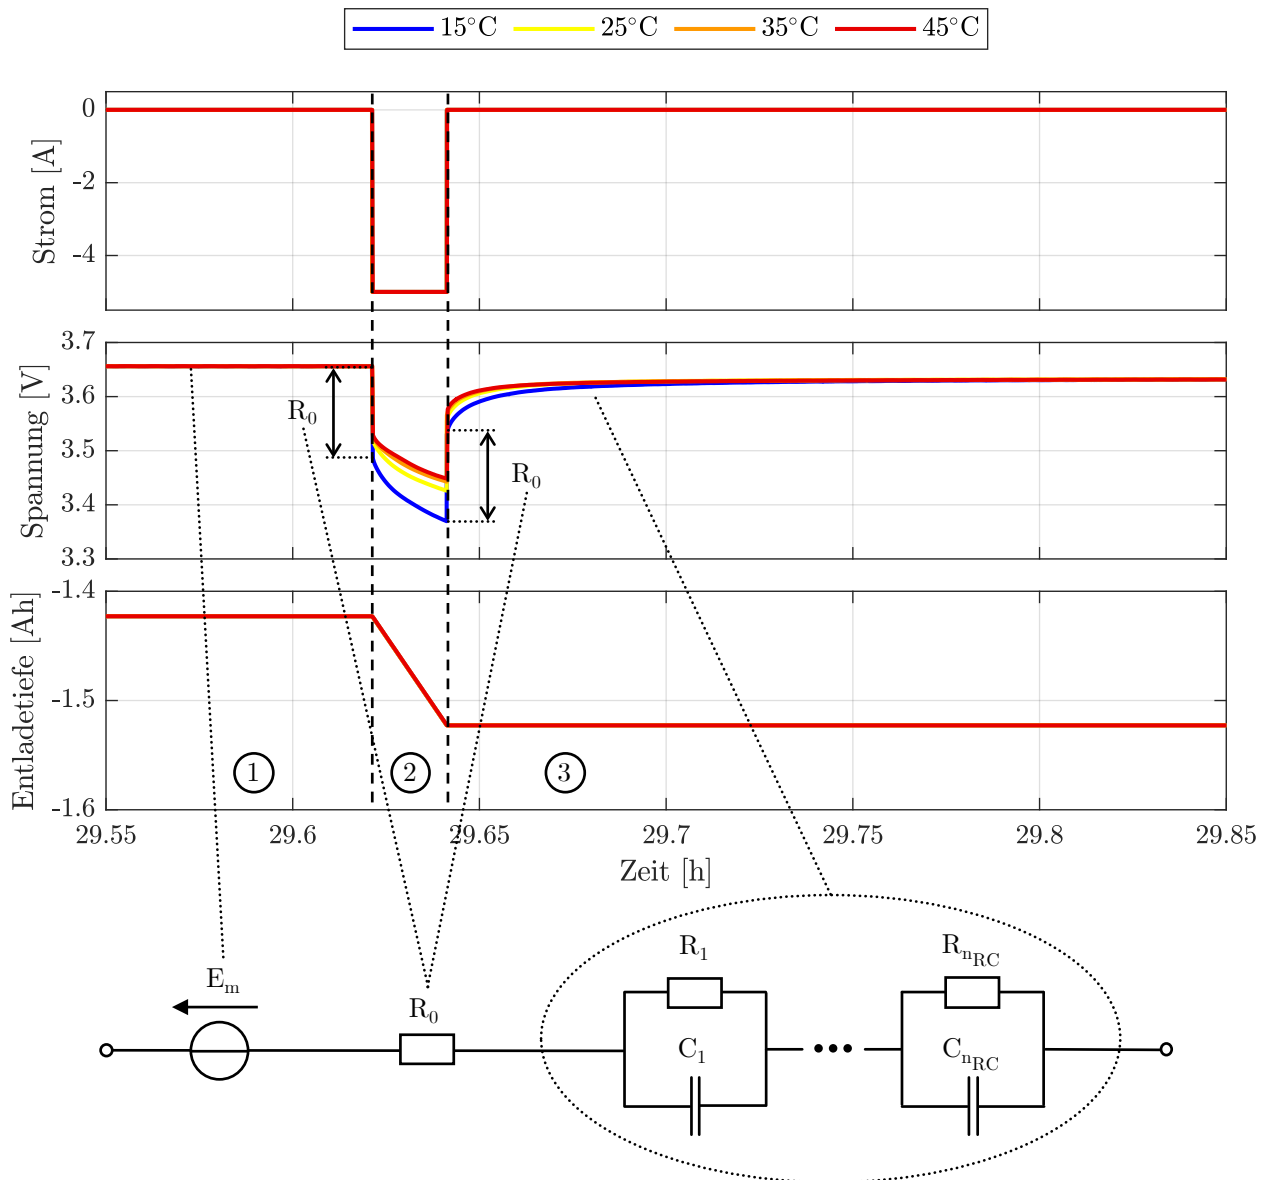
**Abbildung 2.8:** Nyquist- und Bode-Diagramme einer PAN-Zelle bei einer Veränderung des Ladezustands (links) und der Temperatur (rechts).



**Abbildung 2.9:** HPPC-Test zur Parameteridentifikation einer SMG-Zelle.


sinusförmigen Anregung den Ladezustand stärker ändert und damit verbunden nichtlineare Effekte auftreten. Zudem erfolgt für eine Verringerung des Signal-Rausch-Verhältnisses eine Messung über mehrere Perioden, sodass die Erfassung des dynamischen Verhaltens bereits für einen Betriebspunkt einen hohen Zeitaufwand erfordert.

Neben den Verfahren im Frequenzbereich lässt sich die Dynamik der Zelle auch direkt im Zeitbereich identifizieren. Die Charakterisierung im Zeitbereich erfolgt meist mit einem Hybrid-Pulse-Power-Characterization-Testprofil (HPPC-Testprofil). Der Test regt die Zelle mit definierten Strompulsen an und misst die resultierende Spannungsantwort. Abbildung 2.9 zeigt exemplarisch die Anregung einer SMG-Zelle mit einem HPPC-Profil (siehe Abbildung A.3 für die PAN-Zelle). Die Pulse des HPPC-Testprofil dienen gleichzeitig dazu, verschiedene Ladezustände einzustellen, um die Zelle an verschiedenen Betriebspunkten zu charakterisieren. Führt man das Prozedere bei verschiedenen Temperaturen durch, so lässt sich eine Systemidentifikation über den entsprechenden SOC- und Temperaturbereich durchführen. Das Profil setzt sich aus wiederholten Strompulsen mit hoher Amplitude, gefolgt von einem inversen Puls mit niedriger Amplitude zusammen. Es ermöglicht eine vollständige Charakterisierung einer Zelle mit 50 Stützstellen in 100 h je Temperaturstufe. Zudem lässt sich aus den Pulsen, wie in Abschnitt 2.2.2 beschrieben, direkt die schrittweise Ruhespannungskennlinie identifizieren.



**Abbildung 2.10:** Vergrößerter Ausschnitt eines Pulses aus dem HPPC-Testprofil mit Zuordnung eines elektronischen Ersatzschaltbilds.


Abbildung 2.10 zeigt in einem vergrößerten Ausschnitt, die Spannungsantwort einer SMG-Zelle für einen Puls aus dem HPPC-Profil. Die Pulsanregung lässt sich in drei Bereiche unterteilen: Im ersten Bereich befindet sich die Zelle im eingeschwungenen Ruhezustand. Dieser Bereich eignet sich, im Rahmen der statischen Identifikation, die Ruhespannung für die entsprechende Entladetiefe beziehungsweise den zugehörigen SOC zu ermitteln. Mit der ersten Flanke des Entladepulses ist ein instantaner Spannungsabfall zu beobachten, der gemäß dem Ohmschen Gesetz dem Ohmschen Innenwiderstand  $R_0 = \Delta U / \Delta I$  der Zelle entspricht. In der Regel wird zur Ermittlung von  $R_0$  das erste gemessene Sample nach dem Strompuls herangezogen, das je nach Abtastrate (meist 1 kHz oder 100 Hz) dem Widerstand nach 1 ms beziehungsweise 10 ms entspricht [179]. Dem instantanen Spannungssprung folgt während



**Abbildung 2.11:** Dynamische Entladung einer SMG-Zelle mit einem WLTP-basierten Stromprofil zur Validierung der identifizierten Parameter.

der Anregung mit einem Entladestrom ein weiterer Abfall der beobachteten Spannung. Dieser setzt sich aus der Entladung der Zelle und der damit einhergehenden Änderung der Ruhespannung sowie der Polarisationspannung zusammen. In Abbildung 2.10 ist deutlich die Temperaturabhängigkeit zu erkennen. Auch wenn dieser zweite Bereich nach Bereinigung der Zellspannung um die sich ändernde Ruhespannung für die Identifikation des dynamischen Verhaltens grundsätzlich geeignet wäre, erfolgt die Identifikation der Parameter in der Regel in der Relaxationsphase (Phase 3). Die dritte Phase lässt sich zum einen eindeutig einer Entladetiefe zuordnen und zum anderen entfällt die sich ändernde Ruhespannung. Mit der positiven Stromflanke des Entladepulses springt die Zellspannung um  $\Delta U = R_0 \Delta I$  und schwingt zum Ruhezustand ein, der aufgrund der Entladung der Zelle in einer niedrigeren Spannung im Vergleich zur Spannung vor dem Puls resultiert.

Zusammenfassend eignet sich die EIS besonders um hochdynamische Effekte zu identifizieren, die sich aufgrund einer Mittelung über mehrere Perioden messtechnisch sehr gut erfassen lassen. Die Berücksichtigung von Effekten mit längerer Zeitkonstante benötigt jedoch lange Messzeiten und gestaltet sich aufgrund des nichtlinearen Batterieverhaltens herausfordernd. Für Messungen mit niedrigerer Abtastrate oder Simulationen mit größerer Schrittweite (ab etwa 100 ms) spielen jedoch diese hochdynamischen Effekte keine Rolle mehr, da sie sich



**Abbildung 2.12:** Konstantstrom-Entladung und -Ladung einer SMG-Zelle mit dem maximal zulässigen Ladestrom zur Ermittlung des maximalen Widerstands.

nicht vom Innenwiderstand  $R_0$  unterscheiden lassen. Vor diesem Hintergrund und der kürzeren Charakterisierungszeit ist für die Anwendung in dieser Arbeit eine Identifikation im Zeitbereich vorteilhafter.

Abbildungen 2.11 und A.4 ergänzen einen dynamischen Entladungstest und Abbildungen 2.12 und A.5 einen Konstantstrom-Test. Der dynamische Entladungstest belastet die Zelle mit einem Stromprofil, das auf dem Worldwide-harmonized-Light-vehicles-Test-Procedure (WLTP)-Fahrzyklus basiert und sowohl Last- als auch Rekuperationsphasen beinhaltet. Die dynamische Entladung orientiert sich an der angestrebten Anwendung in Elektro- und Hybridfahrzeugen und eignet sich zur Validierung der identifizierten Parameter. Der Konstantstrom-Test entlädt und lädt die Zelle mit dem maximal zulässigen Ladestrom. Er eignet sich zur Identifikation des maximalen Widerstands, den die Zelle nach Einschwingen der RC-Glieder besitzt. Zur Validierung lässt sich mit der Messung zudem das Einschwingverhalten der Zelle plausibilisieren.

## 2.3 Fehler in Batteriesystemen


Fehler in Lithium-Ionen-Batteriesystemen lassen sich in interne und externe Fehler unterteilen (siehe auch Tabellen 1.1-1.3) [123, 146, 278]. Erstere bezeichnen Zelldefekte wie Überladung,

Überentladung, externe oder interne Kurzschlüsse, Überhitzung, beschleunigte Alterung sowie thermisches Durchgehen. Ein fehlerhafter Sensor oder eine fehlerhafte Zustandsschätzung im BMS kann eine Überladung oder Überentladung verursachen. Ein interner Kurzschluss resultiert aus einem Defekt in der Separatorschicht zwischen den Elektroden [286]. Wenn der Kurzschlusspfad nicht zwischen den Elektroden, sondern an den Zellterminals auftritt, spricht man von einem externen Kurzschluss [181, 278]. Kurzschlüsse tragen zur Inhomogenität im Batteriesystem bei und können zu einer Unterentladung führen. Besonders kleine Widerstände führen zu einer schnellen Entladung der betroffenen Zellen und zu einer hohen Wärmegenerierung, die zu einer Überhitzung führen kann. Eine Überhitzung kann zudem aus einem externen Wärmeeintrag oder einem Defekt im Kühlsystem resultieren. Im Allgemeinen führt eine erhöhte Temperatur zu einer beschleunigten Degradation [57], die sich durch eine erhöhte Kapazitätsabnahme und einen übermäßigen Widerstandsanstieg äußert. Jeder der internen Fehler kann zu einem thermischen Durchgehen führen, was auch der kritischste Fehler ist und mit einem Aufblähen der Batterie, dem Auslaufen des Elektrolyts, Rauch, Feuer und einer Explosion einhergehen kann [123, 278].

Externe Fehler sind Sensor- oder Aktorf Fehler im Batteriesystem [123]. Konventionelle Lithium-Ionen-Batteriesysteme setzen Spannungs-, Strom- und Temperatursensoren ein. Fehlerhafte Sensoren können zu einer falschen Zustandsschätzung führen, was wiederum zu fehlerhaftem Betrieb, wie Überladung, Unterentladung oder Überhitzung und beschleunigter Degradation des Batteriesystems führt [303]. Zu den Akteuren gehören die Zell- und Hochvoltverbinder sowie das Kühlsystem. Ähnlich wie die Sensoren können auch die Verbindungen des Strompfads fehlerhaft sein oder im Laufe der Zeit durch Vibration oder Korrosion altern [312]. Eine fehlerhafte Zellverbindung führt zu einem erhöhten Widerstand, der bei parallel geschalteten Zellen zu einer ungleichen Stromverteilung und bei seriell geschalteten Batteriesystemen zu lokalen Hotspots führt [207]. Ein Leck in den Kühlkanälen, eine defekte Pumpe oder einen defekten Lüfter können einen Fehler im Kühlsystem verursachen [300]. Im Allgemeinen können externe Fehler weitere interne Fehler oder ein thermisches Durchgehen der Zellen verursachen, sofern sie nicht erkannt werden und nicht angemessen darauf reagiert wird [146].

### 2.3.1 Entstehung interner Kurzschlüsse

Das Ziel jeder industriellen Zellproduktion, die breit eingesetzte und kommerziell genutzte Batterien herstellt, ist es, Fehler in den Zellen zu vermeiden. Aktuelle Studien zeigen jedoch, dass immer noch schwerwiegende Fehler in Batteriesystemen auftreten, die in den meisten Fällen durch ISCs ausgelöst werden [86]. Wang, Mao u. a. bestätigen, dass es sich bei den meisten Auslösern thermischen Durchgehens um interne Kurzschlüsse handelt und ISCs laut Maleki und Howard der Hauptgrund für Rückrufe von Lithium-Ionen-Batterien sind [188, 288]. Dieser Abschnitt befasst sich deshalb mit der Entstehung und den resultierenden



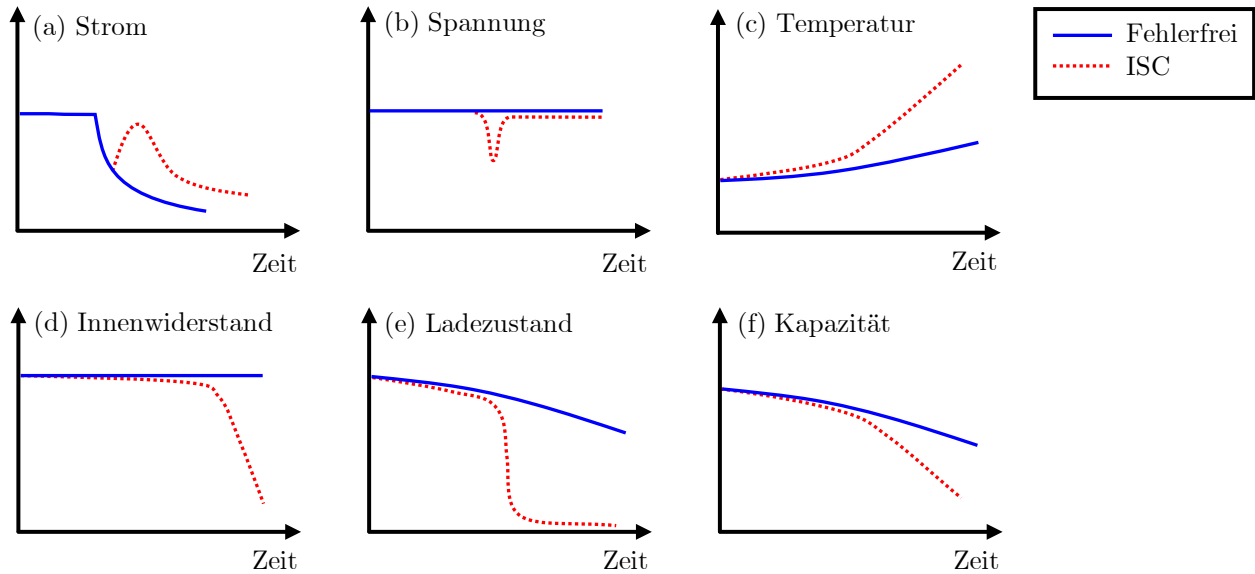
**Abbildung 2.13:** Entstehung und Auslöser interner Kurzschlüsse in Lithium-Ionen-Batterien (angelehnt an [180, 318]).

Diagnosemöglichkeiten interner Kurzschlüsse, die in dieser Arbeit eine gesonderte Stellung einnehmen.

Ein ISC tritt immer dann auf, wenn die normalerweise durch den Separator gewährleistete elektrische Isolation zwischen den Elektroden nicht mehr gegeben ist. Dadurch werden Lithium-Ionen und Elektronen an der Anode freigesetzt und fließen unkontrolliert zur Kathode [278]. In der Folge setzt sich die gespeicherte Energie schnell frei, wodurch die lokale Temperatur über die kritische Temperatur ansteigt. Sobald die kritische Temperatur erreicht ist, ist ein thermisches Durchgehen unvermeidbar. Mögliche Ursachen für das Versagen des Separators sind physischer, thermischer oder elektrischer Missbrauch [188].

Abbildung 2.13 fasst unterschiedliche Auslöser interner Kurzschlüsse zusammen. Ein externer Wärmeeintrag kann beispielsweise aus einem Designfehler oder einem vorangegangenen Fehler einer externen Komponente, wie beispielsweise einem Kabelbrand, resultieren. Zu den Designfehlern, die zu einer externen Wärmezufuhr führen, gehört eine unzureichende Kühlung oder externe Komponenten, die bei einer höheren Temperatur operieren. Dazu gehören beispielsweise Stromschienen, elektronische Bauteile, Inverter oder Motoren, die zu nah an den Batteriezellen positioniert sind [180]. Die Überhitzung kann schließlich zu einer Schmelzung, Schrumpfung oder einem Kollaps der Separatorschicht führen [278]. Elektrischer Missbrauch fasst Überladung [86, 158], Überspannung [180], Tiefentladung [187] oder Überstrom [16] zusammen. Häufig resultiert aus dem elektrischen Missbrauch ein Dendritenwachstum, von denen der Separator durchstoßen wird. Während ein Überladen oder ein Überstrom zu Lithium-Dendriten führt, verursacht eine Tiefentladung ein instabiles Anodenpotential, sodass Kupfer gelöst wird und beim anschließenden Laden unkontrolliert, in Form von Kupfer-Dendriten, auf der Anode abgeschieden wird. Kleinere Dendriten verbrennen in der Regel sobald sie in Kontakt mit der Kathode kommen, was an einem kurzen Spannungseinbruch zu erkennen ist. Formieren sich ausgeprägtere Strukturen, so können diese zu einem Kurzschlusspfad zwischen den Elektroden führen. Weitere ISC-Auslöser sind physikalische Beschädigung der Separatorschicht.





**Abbildung 2.14:** Effekte eines internen Kurzschlusses auf die messbaren Größen (a-c) und internen Zustände und Parameter (d-f) einer Zelle (angelehnt an [318]).

torschicht durch Quetschen, Penetration, Einklemmen, Verbiegen oder eine Verschiebung beziehungsweise ungenaue Ausrichtung des Separators [98, 229, 230, 288]. Auch Grate auf den Elektroden können mit der Zeit zu einer Überbeanspruchung des Separators führen. Darüber hinaus besteht die Möglichkeit der Kontamination mit (metallischen) Fremdpartikeln während der Zellherstellung, die beispielsweise von Werkzeugabrieb oder Stromableitern stammen. Größere Fremdkörper können in den Separator eindringen oder diesen durchstechen und direkt einen Kurzschlusspfad ausbilden. Kleinere Fremdkörper können sich im Elektrolyt lösen, den Separator passieren und in der Folge metallische Dendriten ausbilden [318].

### 2.3.2 Effekte interner Kurzschlüsse

Tritt in einer Zelle ein ISC auf, so zeigt die Zelle ein anomales Verhalten. Dieses ist sowohl an ihren direkt messbaren Größen als auch in den internen Zuständen und Parametern zu beobachten. Abbildung 2.14 fasst die Veränderungen zusammen, die eine ISC-Zelle (rot gepunktet) im Vergleich zu einer fehlerfreien Zelle (blau) zeigt. Während in rein seriell verschalteten Batteriesystemen (Xs1p-Konfiguration) der Laststrom der Hochvoltbatterie direkt den Zellstrom vorgibt, äußert sich der ISC in mehr-p-Systemen mit Strommessung an jeder Einzelzelle, wie IBS, durch einen Ladestrom an der fehlerhaften Zelle (Abbildung 2.14a). Dieser resultiert aus dem Selbstbalancierungseffekt paralleler Zellen. Seien in einem vereinfachten Systemmodell  $E_{m,1}$  und  $E_{m,2}$  die Ruhespannungen und  $R_{0,1}$  und  $R_{0,2}$  die Innenwiderstände zweier paralleler Zellen, so entspricht der Balancierungsstrom

$$i_{\text{bal}} = \frac{\Delta E_m}{R_{0,1} + R_{0,2}}, \quad (2.12)$$

wobei  $\Delta E_m = E_{m,2} - E_{m,1}$  die Ruhespannungsdifferenz der beiden Zellen ist und durch die Selbstentladung der defekten Zelle verursacht wird. Zudem ist ein Einbruch der Zellspannung zu beobachten (Abbildung 2.14b), der, ähnlich einer externen Last, durch den internen Kurzschluss verursacht wird. Für einen Kurzschlusswiderstand  $R_{\text{ISC}}$  beträgt der Kurzschlussstrom

$$i_{\text{ISC}} = \frac{-E_m}{R_0 + R_{\text{ISC}}} \quad (2.13)$$

an einer fehlerhaften Zelle mit Ruhespannung  $E_m$  und Innenwiderstand  $R_0$ . Dieser interne Stromfluss führt an den Terminals zu einer gemessenen Zellspannung von

$$v_{\text{ter}} = \left(1 - \frac{R_0}{R_0 + R_{\text{ISC}}}\right) E_m. \quad (2.14)$$

Die Ohmsche Wärmegenerierung, die zu einem Temperaturanstieg des Zellwickels führt (Abbildung 2.14c), ergibt sich in dem vereinfachten Modell gemäß

$$P_{\text{ISC}} = (R_0 + R_{\text{ISC}}) \cdot i_{\text{ISC}}^2 = \frac{E_m^2}{R_0 + R_{\text{ISC}}}. \quad (2.15)$$

Aus (2.15) wird ersichtlich, dass der Kurzschlussstrom beziehungsweise die Ruhespannung quadratisch in die Wärmegenerierung eingeht. Besonders bei vollgeladenen Zellen, aber auch bei einem kleinen Kurzschlusswiderstand  $R_{\text{ISC}}$  (größerer Kurzschlussstrom  $i_{\text{ISC}}$  gemäß (2.13)) resultiert deshalb eine größere Wärmegenerierung, die zu einem schnellen Temperaturanstieg führt. Der an den Terminals ermittelte Innenwiderstand der Zelle ergibt sich in dem vereinfachten Modell gemäß

$$R_{\text{ter}} = \frac{R_0 R_{\text{ISC}}}{R_0 + R_{\text{ISC}}}. \quad (2.16)$$

Eine signifikante Verringerung des Innenwiderstands, wie in Abbildung 2.14d dargestellt, ist aber erst in einer sehr späten Phase zu beobachten. So reduziert sich der an den Terminals ermittelte Widerstand bei einem Zelleninnenwiderstand von  $R_0 = 10 \text{ m}\Omega$  und einem Kurzschlusswiderstand von  $R_{\text{ISC}} = 10 \Omega$  um weniger als 0.1 %. Durch die resultierende Selbstentladung der Zelle mit dem Strom  $i_{\text{ISC}}$  verringert sich der Ladezustand der fehlerhaften Zelle (Abbildung 2.14e), was in einer geringeren Kapazität resultiert (Abbildung 2.14f).

## 2.4 Methoden und Definitionen für die Fehlerdiagnose

Für die datengetriebene und modellbasierte Fehlerdiagnose existieren in der bekannten Literatur hilfreiche Werkzeuge, die auch in dieser Arbeit Anwendung finden. Dazu zählt die Singulärwertzerlegung (Abschnitt 2.4.1) und, darauf aufbauend, die PCA (Abschnitt 2.4.2), die das Lernen von Datenmodellen basierend auf den systematischen Variationen in den Trainingsdaten ermöglicht. Für die Evaluation der PCA-Projektionen kommt als verallgemei-

nerstes Distanzmaß der Mahalanobis-Abstand zum Einsatz (Abschnitt 2.4.3). Die Erweiterung der linearen PCA mit der Kernel-Methode erlaubt das datengetriebene Lernen und anschließende Monitoring in Anwesenheit von nichtlinearen und nicht-Gauß-verteiltern Daten (Abschnitt 2.4.4). Bei der Evaluation der kernbasierten Kontrollstatistiken hilft eine Kern-dichteschätzung (Abschnitt 2.4.5). Abschnitt 2.4.6 stellt die strukturelle Analyse vor, die sich als hilfreiches Werkzeug für die modellbasierte Fehlerdiagnose erweist. Basierend darauf erlaubt das Kalman-Filter die modellbasierte Schätzung interner Zustände und Parameter (Abschnitt 2.4.7).

### 2.4.1 Singulärwertzerlegung

Die Singulärwertzerlegung (Singular-Value-Decomposition, SVD) zählt zu den wichtigsten Matrixfaktorisierungen und bildet die Basis für eine große Bandbreite an datengetriebenen Verfahren. Die Methode liefert eine numerisch stabile Matrixzerlegung, von der garantiert ist, dass sie für jede komplexe Matrix existiert [24]. Die SVD eignet sich, um Low-Rank-Matrixapproximationen zu finden, Pseudo-Inverse von nicht-quadratischen Matrizen zu berechnen und die Lösung von Gleichungssystemen der Form  $\mathbf{A}\mathbf{x} = \mathbf{b}$  mit  $\mathbf{A} \in \mathbb{C}^{n \times m}$ ,  $\mathbf{x} \in \mathbb{C}^m$  und  $\mathbf{b} \in \mathbb{C}^n$  zu finden. Zudem ist sie in der Systemidentifikation und Regelungstheorie beispielsweise zur ordnungsreduzierten Modellbildung (Reduced-Order-Modelling) weit verbreitet [201]. Die SVD verallgemeinert das Konzept der schnellen Fourier-Transformation (Fast-Fourier-Transform), die in idealisierten Umgebungen arbeitet, während die SVD eine allgemeinere datengetriebene Technik darstellt [24]. In dieser Arbeit bildet die SVD die Grundlage der PCA, die wiederum die Basis vieler Probleme aus dem Bereich der Dimensionsreduktion, Datenkompression oder Clusteranalyse ist.

Bei der SVD handelt es sich um eine eindeutige Matrixzerlegung

$$\mathbf{X} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^*, \quad (2.17)$$


für jede komplexe Matrix  $\mathbf{X} \in \mathbb{C}^{n \times m}$ . Das Superskript  $*$  bezeichnet die transponierte, komplex konjugierte einer Matrix, was für reelle Matrizen der Transponierten entspricht. Die Spalten der Matrix  $\mathbf{U} \in \mathbb{C}^{n \times n}$  entsprechen den linken Singulärvektoren und die Spalten von  $\mathbf{V} \in \mathbb{C}^{m \times m}$  den rechten Singulärvektoren. Beide Matrizen  $\mathbf{U}$  und  $\mathbf{V}$  sind unitär, das heißt  $\mathbf{U}\mathbf{U}^* = \mathbf{U}^*\mathbf{U} = \mathbf{I}_{n \times n}$  beziehungsweise  $\mathbf{V}\mathbf{V}^* = \mathbf{V}^*\mathbf{V} = \mathbf{I}_{m \times m}$ . Bei  $\mathbf{\Sigma} \in \mathbb{R}^{n \times m}$  handelt es sich um eine reelle Matrix der Form

$$\mathbf{\Sigma} = \left[ \begin{array}{c|c} \sigma_1 & \mathbf{0}_{r \times (m-r)} \\ \vdots & \\ \sigma_r & \\ \hline \mathbf{0}_{(n-r) \times r} & \mathbf{0}_{(n-r) \times (m-r)} \end{array} \right] \quad (2.18)$$

mit den absteigend sortierten Singulärwerten  $\sigma_1 \geq \dots \geq \sigma_r > 0$ . Die Anzahl  $r$  der nicht-negativen Singulärwerte entspricht dem Rang von  $\mathbf{X}$ . Die maximale Anzahl an Singulärwerten ist  $\min(n, m)$ . Ohne Beschränkung der Allgemeinheit wird nachfolgend zur Übersichtlichkeit  $n \geq m$  angenommen, was durch Transponieren der Ausgangsmatrix für jede Matrix  $\mathbf{X}$  erreicht werden kann. Für die Singulärwertzerlegung folgt dann

$$\mathbf{X} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^* = \begin{bmatrix} \hat{\mathbf{U}} & \hat{\mathbf{U}}^\perp \end{bmatrix} \begin{bmatrix} \hat{\mathbf{\Sigma}} \\ \mathbf{0}_{(n-r) \times m} \end{bmatrix} \mathbf{V}^* = \hat{\mathbf{U}}\hat{\mathbf{\Sigma}}\mathbf{V}^*, \quad (2.19)$$

wobei  $\hat{\mathbf{U}}^\perp \in \mathbb{C}^{n \times (m-n)}$  einen komplementären und orthogonalen Vektorraum zu  $\hat{\mathbf{U}} \in \mathbb{C}^{n \times m}$  aufspannt. Bei  $\hat{\mathbf{\Sigma}} \in \mathbb{R}^{m \times m}$  handelt es sich um eine quadratische Diagonalmatrix mit den Singulärwerten auf der Diagonale. Da  $\mathbf{\Sigma}$  die Matrix  $\hat{\mathbf{U}}^\perp$  zu Null gewichtet, ergibt sich auf der rechten Seite von (2.19) die ökonomische Version der SVD, die lediglich die ersten  $m$  Spalten von  $\mathbf{U}$  berechnet. Abbildung 2.15 visualisiert beide Varianten der SVD und deutet zudem, durch eine weiß gestrichelte Linie, die reduzierte SVD an, die direkt eine Low-Rank-Matrixapproximation ermöglicht. Durch das Verkleinern der Matrix  $\hat{\mathbf{\Sigma}}$  beziehungsweise dem



**Abbildung 2.15:** Vollständige und ökonomische Singulärwertzerlegung sowie reduzierte Singulärwertzerlegung (weiß gepunktet) zur Low-Rank-Matrixapproximation (angelehnt an [24]).

Abschneiden der kleinsten Singulärwerte resultiert direkt eine Matrixapproximation kleineren Ranges. Diese Approximation ist aus der Numerik motiviert, bei der Singulärwerte unter einem bestimmten Schwellwert als Null betrachtet werden. Setzt man diesen Schwellwert höher, so folgt direkt diese Approximation.

## 2.4.2 Hauptkomponentenanalyse

Die Hauptkomponentenanalyse (Principal-Component-Analysis, PCA) zerlegt hochdimensionale Daten in ihre statistisch aussagekräftigsten Faktoren. Die Grundannahme der PCA ist dabei, dass die Richtung mit der größten Streuung den größten Informationsgehalt beinhaltet. Dies macht die PCA zu einem mächtigen Werkzeug aus dem Bereich des unüberwachten maschinellen Lernens. Zu beachten ist jedoch, dass die PCA nur lineare Variationen in den

Daten findet. Zudem betrachtet die PCA die Daten als Stichproben einer multivariaten Gauß-Verteilung [316]. Dennoch zeigt die Methode meist auch dann ein robustes Verhalten, wenn diese Eigenschaften nur näherungsweise erfüllt sind. Darüber hinaus erfordert die Anwendung der PCA zentrierte, mittelwertfreie Daten. Im Falle unterschiedlicher Signale ist zudem eine Studentisierung der Variablen sinnvoll.

Basierend auf der zentrierten Datenmatrix  $\mathbf{X} \in \mathbb{R}^{n \times m}$  approximiert

$$\mathbf{C} = \frac{1}{n-1} \mathbf{X}^T \mathbf{X} \in \mathbb{R}^{m \times m} \quad (2.20)$$

die Kovarianzmatrix, die sich mithilfe der SVD gemäß

$$\mathbf{C} = \mathbf{U} \mathbf{\Sigma} \mathbf{V}^* \quad (2.21)$$

zerlegen lässt. Da die Kovarianzmatrix  $\mathbf{C}$  symmetrisch und positiv definit ist, gilt  $\mathbf{P} := \mathbf{U} = \mathbf{V}^*$ . Die Spalten von  $\mathbf{P} = [\mathbf{p}_1 \dots \mathbf{p}_m] \in \mathbb{R}^{m \times m}$  entsprechen den Eigenvektoren von  $\mathbf{C}$ , sind orthogonal, haben die Länge  $\|\mathbf{p}_j\| = 1$  und rotieren somit den von  $\mathbf{C}$  aufgespannten Raum in Richtung der größten Datenvarianz. Die Matrix  $\mathbf{\Lambda} = \mathbf{\Sigma}$  ist eine Diagonalmatrix  $\mathbf{\Lambda} = \text{diag}(\lambda_1 \dots \lambda_m) \in \mathbb{R}^{m \times m}$  mit den Singulärwerten entsprechend den absteigend geordneten Eigenwerten  $\lambda_1 \geq \dots \geq \lambda_m \geq 0$  auf der Diagonale, sodass die Zerlegung

$$\mathbf{C} = \mathbf{P} \mathbf{\Lambda} \mathbf{P}^T = \begin{bmatrix} | & & | \\ \mathbf{p}_1 & \cdots & \mathbf{p}_m \\ | & & | \end{bmatrix} \begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_m \end{bmatrix} \begin{bmatrix} - & \mathbf{p}_1 & - \\ & \vdots & \\ - & \mathbf{p}_m & - \end{bmatrix} \quad (2.22)$$

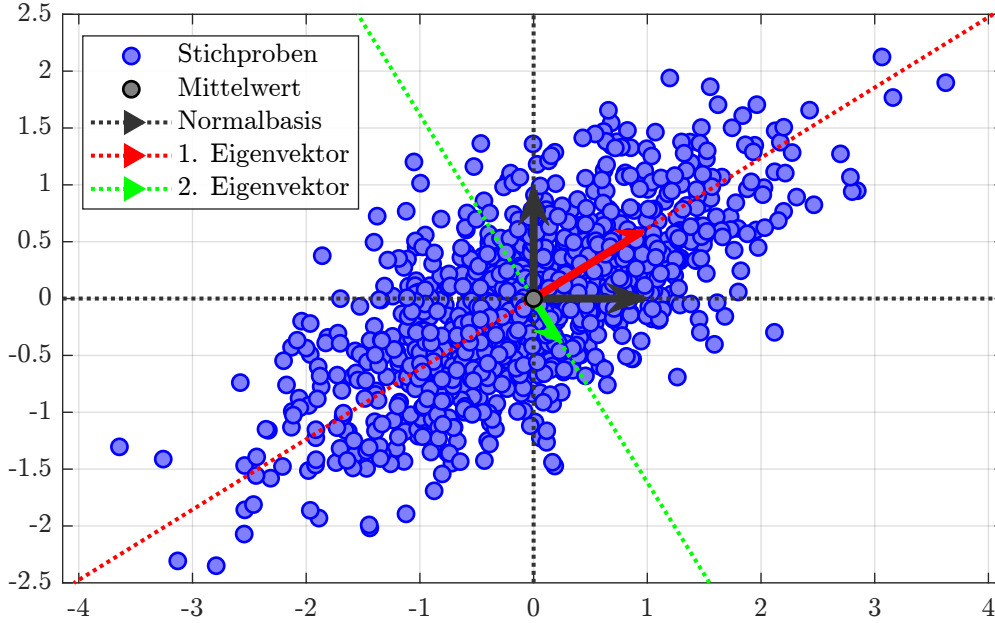
resultiert. Die Eigenwerte  $\lambda_i$  geben die Varianz der Daten entlang der Basis im neuen Raum an. Der Raum  $\tilde{\mathbf{P}} = \mathbf{P} \mathbf{\Lambda}$  entspricht einer gedrehten und skalierten Version des ursprünglichen Raumes basierend auf den Trainingsdaten.

Abbildung 2.16 visualisiert die skalierten Hauptkomponenten  $\tilde{\mathbf{P}} = \mathbf{P} \mathbf{\Lambda}$  exemplarisch für eine zweidimensionale Datenverteilung. Die in blau dargestellten  $n = 1000$  Stichproben entsprechen den Realisierungen einer mittelwertfreien Normalverteilung mit der Kovarianzmatrix

$$\mathbf{\Sigma}_c = \begin{bmatrix} 1 & 0.5 \\ 0.5 & 0.5 \end{bmatrix}. \quad (2.23)$$

Die schwarzen Pfeile zeigen die Orientierung einer Orthonormalbasis in  $\mathbb{R}^2$ . Der rote Pfeil entspricht der skalierten ersten Hauptkomponente und zeigt in Richtung der größten Datenvarianz. Orthogonal dazu zeigt ein grüner Pfeil den skalierten, zweiten Eigenvektor.

Aufbauend auf diese Orientierung und Sortierung eignet sich die PCA zur Dimensionsreduktion. Gerade für hochdimensionale Daten ist meist eine geringe Variation in den letzten Hauptkomponenten zu beobachten. Durch Abschneiden der Diagonalmatrix  $\hat{\mathbf{\Lambda}} \in \mathbb{R}^{\beta \times \beta}$  bei



**Abbildung 2.16:** Normalverteilte Stichproben (blau) mit ihrem Mittelwert (grau) und den ermittelten Hauptkomponenten (rot und grün). Zur besseren Darstellung entspricht die Länge der Eigenvektoren in der Abbildung  $\sqrt{\lambda_i}, i \in \{1, 2\}$ .

einem bestimmten Eigenwert und Verkleinern der Matrix  $\hat{\mathbf{P}} \in \mathbb{R}^{m \times \beta}$  mit  $\beta < m$  resultiert direkt eine optimale Approximation von  $\mathbf{C}$  im Sinne der größten Datenvarianz.

Auch für die Fehlerdetektion erfolgt eine Aufteilung von  $\mathbf{\Lambda}$  und  $\mathbf{P}$ . In den beiden resultierenden orthogonalen Unterräumen  $\mathbb{S}_{\text{pc}} \equiv \text{span}\{\mathbf{p}_1 \dots \mathbf{p}_\beta\}$  und  $\mathbb{S}_{\text{res}} \equiv \text{span}\{\mathbf{p}_{\beta+1} \dots \mathbf{p}_m\}$  erfolgt dann getrennt voneinander das Monitoring. Im Hauptraum  $\mathbb{S}_{\text{pc}}$ , bestehend aus den ersten Hauptkomponenten, lassen sich Änderungen in den systematischen Variationen der Daten detektieren. Der Residuen-Raum  $\mathbb{S}_{\text{res}}$  erlaubt Veränderungen im Rauschverhalten zu detektieren, falls sich im Test die Verteilung der unsystematischen Projektionen ändert.

Neben der Kovarianzmatrix gemäß (2.20), die dem inneren Produkt der Spalten von  $\mathbf{X}$  entspricht, existiert auch die Gram-Matrix

$$\mathbf{G} = \frac{1}{n-1} \mathbf{X} \mathbf{X}^T \in \mathbb{R}^{n \times n}, \quad (2.24)$$

die dem äußeren Produkt der Spalten von  $\mathbf{X}$  entspricht. Für die PCA ist es dabei unerheblich, auf Grundlage welcher der beiden Matrizen die Hauptkomponenten und Eigenwerte berechnet werden. Dies wird deutlich, wenn man die Datenmatrix  $\mathbf{X}$  jeweils durch ihre Singulärwertzerlegung  $\mathbf{X} = \mathbf{U} \mathbf{\Sigma} \mathbf{V}^T$  ersetzt. Damit folgt für die Kovarianzmatrix

$$\mathbf{C} = \frac{1}{n-1} \mathbf{V} \mathbf{\Sigma}^2 \mathbf{V}^T \quad (2.25)$$

und für die Gram-Matrix

$$\mathbf{G} = \frac{1}{n-1} \mathbf{U} \mathbf{\Sigma}^2 \mathbf{U}^T. \quad (2.26)$$

Die Eigenvektoren  $\mathbf{V}$  der Kovarianzmatrix entsprechen den Hauptrichtungen. Die Projektionen  $\mathbf{U}\boldsymbol{\Sigma}$  der Daten auf diese Eigenvektoren sind Hauptkomponenten.  $\mathbf{U}$  entspricht auf Einheitslänge skalierten Hauptkomponenten. Die Eigenvektoren der Gram-Matrix sind genau diese skalierten Hauptkomponenten. Auch die Eigenwerte von  $\mathbf{C}$  und  $\mathbf{G}$  stimmen überein, sodass gilt  $\text{rang}(\mathbf{C}) = \text{rang}(\mathbf{G}) \leq \min(n, m)$ .

Die Entscheidung zwischen der Kovarianzmatrix und der Gram-Matrix basiert in der Anwendung üblicherweise darauf, welche der beiden Matrizen kleiner ist. Beispielsweise ist für die Klassifikation von Bildern mit einer großen Anzahl an Pixeln  $m$  und einer vergleichsweise geringen Anzahl an Bildern  $n$  die Wahl der Gram-Matrix sinnvoll. Für die Anwendung der PCA als Monitoring-Methode in Batteriesystemen ist jedoch die Kovarianzmatrix sinnvoller, da die multivariate Verteilung der Zeitreihen aus einer großen Anzahl an Stichproben  $n$  mit einer vergleichsweise geringen Anzahl an Sensorsignalen  $m$  verfügt. Die Anwendung der nichtlinearen KPCA erfordert jedoch die Gram-Matrix, was Verfahren zur optimalen Wahl der Trainingsdaten (vergleiche Abschnitt 4.5.7) motiviert.

### 2.4.3 Mahalanobis-Distanz

Die Mahalanobis-Distanz

$$d_{\text{Mah}}(\mathbf{x}, \boldsymbol{\mu}) = \sqrt{(\mathbf{x} - \boldsymbol{\mu})^T \mathbf{C}^{-1} (\mathbf{x} - \boldsymbol{\mu})} \quad (2.27)$$

kann als eine Erweiterung der euklidischen Distanz

$$d_{\text{Euk}}(\mathbf{x}, \boldsymbol{\mu}) = \sqrt{(\mathbf{x} - \boldsymbol{\mu})^T (\mathbf{x} - \boldsymbol{\mu})} \quad (2.28)$$

angesehen werden [95]. Sie ist ein hilfreiches Werkzeug, um den Abstand eines Punktes  $\mathbf{x}$  zu einer multivariaten Verteilung mit Kovarianzmatrix  $\mathbf{C}$  zu bestimmen. Es handelt sich dabei um eine Verallgemeinerung des Ansatzes, zu messen, wie viele Standardabweichungen ein Punkt  $\mathbf{x} \in \mathbb{R}^n$  vom Mittelwert  $\boldsymbol{\mu} \in \mathbb{R}^n$  der Verteilung entfernt ist. Entsprechend beträgt sie, wie die euklidische Distanz für das Datenzentrum Null.

Das nachfolgende Beispiel verdeutlicht den Unterschied zwischen der euklidischen und der Mahalanobis-Distanz. Aus einer zweidimensionalen Gauß-Verteilung mit Kovarianzmatrix

$$\boldsymbol{\Sigma}_c = \begin{bmatrix} 5 & 4 \\ 4 & 4 \end{bmatrix} \quad (2.29)$$

und Mittelwert  $\boldsymbol{\mu} = [0 \ 0]^T$  werden  $n = 1000$  Stichproben  $\mathbf{X} = [\mathbf{x}_1 \dots \mathbf{x}_n]^T \in \mathbb{R}^{n \times 2}$  gezogen, die in Abbildung 2.17 als blaue Punkte dargestellt sind. Die basierend auf den Stichproben

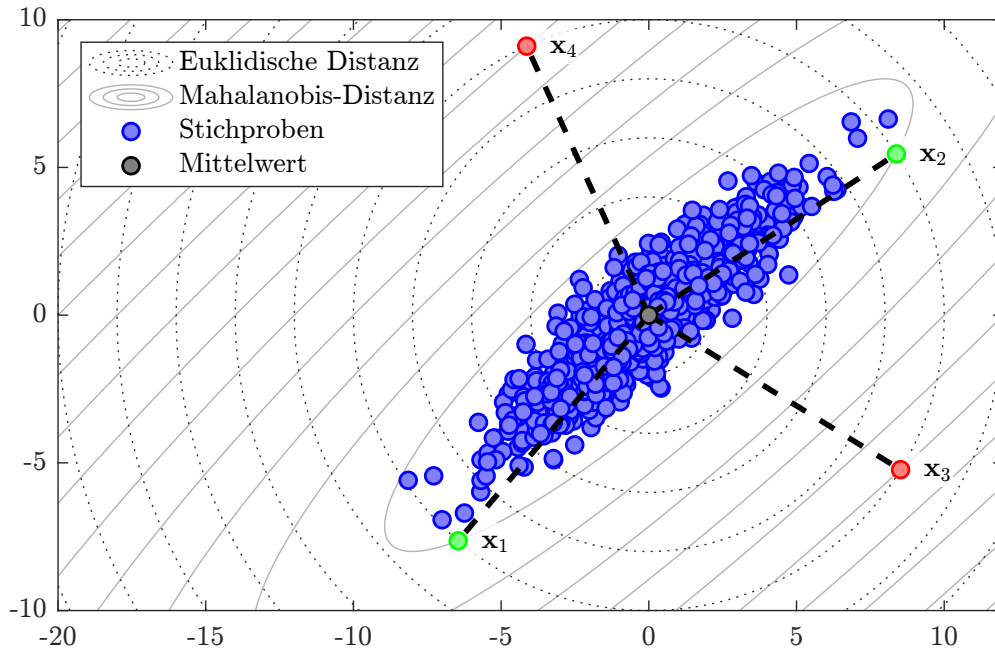


Abbildung 2.17: Vergleich der euklidischen mit der Mahalanobis-Distanz.

geschätzte Kovarianzmatrix ist

$$\mathbf{C} = \frac{1}{n-1} \mathbf{X}^T \mathbf{X} = \begin{bmatrix} 4.9615 & 3.9268 \\ 3.9268 & 3.9726 \end{bmatrix}. \quad (2.30)$$

Abbildung 2.17 zeigt zudem in Grün die Punkte

$$\mathbf{x}_1 = [-6.4526, -7.6396]^T \quad (2.31)$$

$$\mathbf{x}_2 = [ 8.3810, 5.4552]^T \quad (2.32)$$

und in Rot die Punkte

$$\mathbf{x}_3 = [ 8.5230, -5.2306]^T \quad (2.33)$$

$$\mathbf{x}_4 = [-4.1331, 9.1059]^T. \quad (2.34)$$

Der euklidische Abstand (schwarz gepunktet) aller vier Punkte  $\mathbf{x}_i$  zum Mittelwert  $\boldsymbol{\mu}$  beträgt jeweils

$$d_{\text{Euk}}(\mathbf{x}_i, \boldsymbol{\mu}) = 10 \quad \forall i \in [1, 4]. \quad (2.35)$$

Anschaulich spiegelt dies jedoch nicht den erwarteten Abstand zur Verteilung der Daten  $\mathbf{X}$  wider. Die Mahalanobis-Distanz (grau) der grünen Punkte beträgt

$$d_{\text{Mah}}(\mathbf{x}_i, \boldsymbol{\mu}) = 4 \quad \forall i \in \{1, 2\} \quad (2.36)$$



und die der roten Punkte

$$d_{\text{Mah}}(\mathbf{x}_i, \boldsymbol{\mu}) = 14 \forall i \in \{3, 4\}, \quad (2.37)$$

was ihrem Abstand zur Verteilung von  $\mathbf{X}$  gerecht wird. Nach einer Umskalierung der Achsen im transformierten Raum auf Einheitsvarianz entspräche der Mahalanobis-Abstand wiederum dem euklidischen Standardabstand.

#### 2.4.4 Kernel-Methode

Während Abschnitt 4.5 die lineare PCA unter Anwendung der Kernel-Methode und des Kernel-Tricks formal auf nichtlinear variierende Daten erweitert, konzentriert sich dieser Abschnitt darauf, die KPCA intuitiv einzuführen. Der wesentliche Unterschied der KPCA zur PCA besteht darin, dass die Eingangsdaten vor Anwendung der Matrixfaktorisierung nichtlinear transformiert werden [251]. Die nichtlineare Abbildung  $\Phi(\cdot)$  in den sogenannten Merkmalsraum (*Feature-Space*)  $\mathbb{F}$  erfolgt gemäß


$$\Phi : \mathbb{R}^m \rightarrow \mathbb{F}, \mathbf{x} \mapsto \mathbf{x}. \quad (2.38)$$

Basierend auf der Gram-Matrix

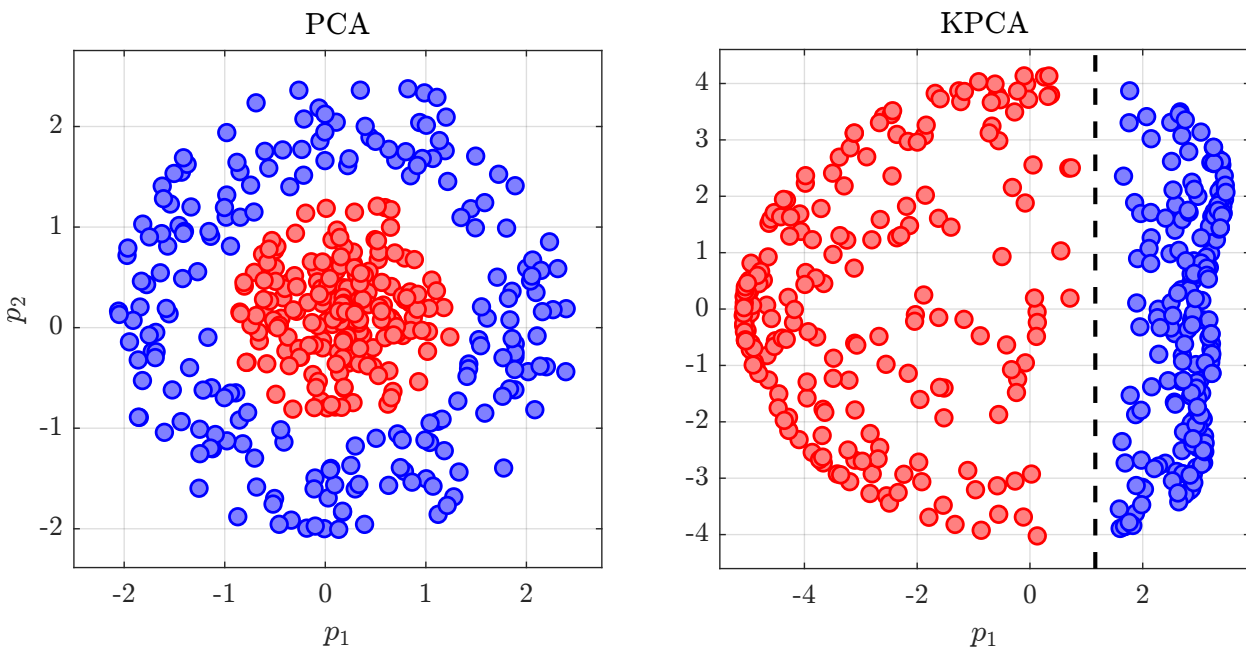
$$\mathfrak{G} = \frac{1}{n-1} \Phi(\mathbf{X})\Phi(\mathbf{X})^T \in \mathbb{R}^{n \times n} \quad (2.39)$$

erfolgt dann die lineare PCA im Merkmalsraum. Da die analytische Berechnung der nichtlinearen Abbildung  $\Phi(\cdot)$  in der Praxis sehr rechenaufwändig oder im Falle eines unendlich-dimensionalen Merkmalsraums unmöglich wäre, haben Schölkopf, Smola und Müller den von SVMs bekannten Kernel-Trick auf die KPCA übertragen [251]. Dieser ermöglicht, lediglich die Skalarprodukte abgebildeter Punkte im Merkmalsraum anstatt ihrer tatsächlichen Repräsentation zu berechnen (siehe Abschnitt 4.5.1).

Um die zusätzlichen Freiheitsgrade der KPCA zu demonstrieren, zeigt Abbildung 2.18 exemplarisch  $n_{\text{Rot}} = 200$  rote und  $n_{\text{Blau}} = 200$  blaue Stichproben, mit  $n = n_{\text{Rot}} + n_{\text{Blau}} = 400$  und  $m = 2$  Dimensionen. Auf diese Daten wird die in Abschnitt 2.4.2 vorgestellte PCA und die KPCA angewandt. Die nichtlineare Abbildung der Daten erfolgt mit einer Gaußschen radialen Basisfunktion. Abbildung 2.19 zeigt links die Projektionen entlang der ersten beiden Hauptkomponenten  $p_1$  und  $p_2$  für die PCA und rechts für die KPCA. Im Falle der PCA existieren lediglich diese zwei Hauptkomponenten, die, wie in Abbildung 2.16 gezeigt, eine Drehstreckung der Daten verursachen. Aufgrund des nicht-eindeutigen Vorzeichens ist zudem eine Spiegelung des Datensatzes möglich. Insbesondere die Drehung und die Spiegelung ist in den in Abbildung 2.19 (links) gezeigten, projizierten Stichproben zu beobachten. Diese lineare Transformation genügt jedoch nicht, das nichtlineare Muster des Datensatzes zu trennen, sodass die Stichproben auch nach der Transformation mit der PCA nicht linear




**Abbildung 2.18:** Zwei exemplarische Cluster zur Demonstration der PCA und KPCA.



**Abbildung 2.19:** Projektion der Cluster aus Abbildung 2.18 mithilfe der PCA (links) und der KPCA (rechts).

separierbar sind. Abbildung 2.19, rechts zeigt für die KPCA die ersten beiden der  $n = 400$  Hauptkomponenten und die Projektion der Stichproben. Da die Hauptkomponenten nach den größten Eigen- beziehungsweise Singulärwerten sortiert sind, enthalten die ersten Hauptkomponenten die Hauptinformation. Aufgrund linearer Abhängigkeiten im Merkmalsraum (siehe Abschnitt 4.5.7) enthalten die letzten Hauptkomponenten keine Information mehr. Dieser Residuen-Teil ist jedoch dennoch für die Fehlerdiagnose relevant, da sich auch mit dieser



**Abbildung 2.20:** Visualisierung des zusätzlichen Freiheitsgrads durch die nichtlineare Abbildung in einen höherdimensionalen Raum.

Untermenge Anomalien detektieren lassen. Die schwarz gestrichelte Linie verdeutlicht, dass die Daten bereits entlang der ersten Hauptkomponente  $p_1$  linear separierbar sind.


Eine intuitive Erklärung für den Vorteil der nichtlinearen Transformation  $\Phi(\cdot)$  liefert Abbildung 2.20. Durch eine Abbildung der Stichproben in den hochdimensionalen Merkmalsraum entstehen mehr Freiheitsgrade. Stichproben, die im Eingangsraum nichtlinear variieren, lassen sich im Merkmalsraum linear separieren. Getrieben von dieser Idee erfolgt die Anwendung der linearen PCA in  $\mathbb{F}$ .

### 2.4.5 Kerndichteschätzer

Die Bewertung der mithilfe der PCA oder KPCA transformierten Daten erfordert die Kenntnis der Verteilung der (fehlerfreien) Trainingsdaten. Für die PCA lassen sich, basierend auf der Normalverteilungsannahme und einem Signifikanzniveau, analytische Schwellwerte zur Fehlerdetektion berechnen. Die KPCA erfordert jedoch eine Schätzung der den Trainingsdaten zugrundeliegenden Verteilung, was in dieser Arbeit mit einer datengetriebenen Methode, der Kerndichteschätzung, erfolgt.

Sind  $n$  Werte  $x_i$  einer Stichprobe gegeben, so schätzt der Kerndichteschätzer die Dichtefunktion der zugrundeliegenden Zufallsvariablen als

$$\hat{f}(x) = \frac{1}{nb} \sum_{i=1}^n K\left(\frac{x - x_i}{b}\right), \quad (2.40)$$



**Abbildung 2.21:** Kerndichteschätzer mit einem Normalkern als Kernfunktion für verschiedene Bandbreiten  $b$ .

wobei  $K(x)$  die Kernfunktion mit  $K(x) \geq 0 \forall x \in \mathbb{R}$  und

$$\int_{-\infty}^{\infty} K(x) dx = 1 \quad (2.41)$$

ist. Für die Bandbreite  $b$  gilt  $b > 0$ . Als Kernfunktionen  $K(x)$  kommen meist symmetrische Funktionen  $K(x) = K(-x)$  zum Einsatz, auch wenn dies keine Voraussetzung ist. Häufig eingesetzte Kernfunktionen sind der Normalkern

$$K_{\text{Norm}}(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}, \quad (2.42)$$

der der Dichtefunktion der Standardnormalverteilung entspricht, der Dreiecks- oder Rechteckkern sowie der Epanechnikov-Kern [193]:

$$K_{\text{Epan}}(x) = \begin{cases} \frac{3}{4}(1 - x^2) & , |x| \leq 1 \\ 0 & , \text{sonst.} \end{cases} \quad (2.43)$$

Die optimale Wahl der Bandbreite  $b$  ist ein nichttriviales Problem, mit dem sich beispielsweise Pflüger befasst [216]. Abbildung 2.21 zeigt das Prinzip der Kerndichteschätzung mit einem Normalkern für verschiedenen Bandbreiten  $b$ . In Schwarz sind  $n = 10$  Realisierungen  $x_i$  einer Zufallsvariable gegeben und gestrichelt die zugehörigen Kernfunktionen, die, nach Gleichung (2.40) summiert, eine Schätzung der Dichtefunktion liefern (durchgezogene Linie). Eine größer werdende Bandbreite  $b$  sorgt dabei für eine zunehmende Glättung der Verteilung.

### 2.4.6 Strukturelle Analyse

Bei der strukturellen Analyse handelt es sich um ein Werkzeug aus der Graphentheorie mit dem sich komplexe Systeme untersuchen lassen. Im Rahmen dieser Arbeit (siehe Abschnitt 5.3) ermöglicht sie, eine optimale Sensormenge zu finden, die Isolierbarkeit von Fehlern zu präzisieren und minimal strukturell überbestimmte Teilsysteme zu finden, auf deren Basis sich Residuen für die Fehlerdiagnose generieren lassen. Dieser Abschnitt führt die grundlegenden Definitionen nach Frisk und Krysander anhand eines Beispielsystems ein [82, 154].

Sei  $\mathbb{W} = \{\mathbb{V}, \mathbb{E}, \mathbb{K}\}$  ein System, bestehend aus einer Menge unbekannter Variablen  $v_i \in \mathbb{V}, i = 1, \dots, n_{\mathbb{V}}$ , Gleichungen  $e_i \in \mathbb{E}, i = 1, \dots, n_{\mathbb{E}}$  und bekannter Variablen  $\bar{k}_i \in \mathbb{K}, i = 1, \dots, n_{\mathbb{K}}$ . Dann stellt der bipartite Graph  $\mathcal{G}(\mathbb{U} \cup \mathbb{E}, \mathbb{A})$  mit den unbekanntem und bekannten Variablen  $\mathbb{U} = \mathbb{V} \cup \mathbb{K}$  sowie der Gleichungsmenge  $\mathbb{E}$  als Knoten  $\mathbb{W}$  strukturell dar.  $\mathbb{A}$  entspricht der Menge aller Kanten zwischen den Knoten. Ein Graph  $\mathcal{G}(\mathbb{U} \cup \mathbb{E}, \mathbb{A})$  ist bipartit, falls sich seine Knoten so in zwei disjunkte Teilmengen aufteilen lassen, dass innerhalb der beiden Teilmengen keine Kanten verlaufen. Eine Kante  $a_{ij} \in \mathbb{A}$  zwischen Gleichung  $e_i \in \mathbb{E}$  und Variable  $v_j \in \mathbb{V}$  oder  $\bar{k}_j \in \mathbb{K}$  ist vorhanden, falls  $v_j$  oder  $\bar{k}_j$  in Gleichung  $e_i$  enthalten ist [154].

Gegeben sei das Beispielsystem

$$\begin{array}{l}
 e_1 : 0 = x_1^2 + 2x_2^3 + \bar{a} \\
 e_2 : 0 = x_1 + 4x_2 - \bar{b} \\
 e_3 : 0 = x_1 + 2(\bar{a} + \bar{b}) \\
 e_4 : 0 = \dot{x}_1 + x_1 \\
 e_5 : 0 = \dot{x}_1 - \frac{\delta}{\delta t} x_1
 \end{array}
 \longrightarrow
 \begin{array}{ccc|cc}
 x_1 & \dot{x}_1 & x_2 & \bar{a} & \bar{b} \\
 \hline
 1 & 0 & 1 & 1 & 0 \\
 1 & 0 & 1 & 0 & 1 \\
 1 & 0 & 0 & 1 & 1 \\
 1 & 1 & 0 & 0 & 0 \\
 1 & 1 & 0 & 0 & 0 \\
 \hline
 \underbrace{\hspace{10em}}_{\mathbf{H}} & & & \underbrace{\hspace{10em}}_{\mathbf{L}} & 
 \end{array}
 \quad (2.44)$$

mit unbekanntem Variablen  $\mathbb{V} = \{x_1, \dot{x}_1, x_2\}$ , Gleichungen  $\mathbb{E} = \{e_1, \dots, e_5\}$  und bekannten Variablen  $\mathbb{K} = \{\bar{a}, \bar{b}\}$ . Die Adjazenzmatrix  $\mathbf{A} = [\mathbf{H}, \mathbf{L}] \in \mathbb{R}^{n_{\mathbb{E}} \times (n_{\mathbb{V}} + n_{\mathbb{K}})}$  hat nicht-leere Einträge für die Variablen von  $\mathbb{V}$ ,  $\mathbb{K}$ , die in einer Gleichung  $e_i$  enthalten sind. Ähnlich wie bei [82, 153, 154] wird angenommen, dass jeder Fehler nur eine Gleichung verletzen kann. Diese Annahme lässt sich ohne Verlust der Allgemeinheit treffen, da sich ein Fehler, der in mehr als einer Gleichung auftritt, durch eine neue Variable  $x_f$  und eine neue Gleichung  $f = x_f$  ersetzen lässt. Analog zu [154] wird die *Strukturelle Redundanz* eines Systems als

$$\varphi_s = \text{s-rang}([\mathbf{H}, \mathbf{L}]) - \text{s-rang}(\mathbf{H}) \quad (2.45)$$

definiert, wobei  $\text{s-rang}(\mathbf{A})$  der strukturelle Rang der Matrix  $\mathbf{A}$  ist. Der strukturelle Rang einer Matrix liefert eine obere Schranke

$$\text{rang}(\mathbf{A}) \leq \text{s-rang}(\mathbf{A}) \quad (2.46)$$

für den Rang einer Matrix und entspricht dem maximalen Rang aller Matrizen mit demselben Nicht-Null-Muster [154]. Ein Teilsystem  $\mathbb{M} \subseteq \mathbb{E}$  ist genau dann *geeignet strukturell überbestimmt* (Properly-Structurally-Overdetermined, PSO), wenn

$$\varphi_s(\mathbb{M} \setminus \{e\}) < \varphi_s(\mathbb{M}), \forall e \in \mathbb{M} \quad (2.47)$$

gilt. Der PSO-Teil von  $\mathbb{M}$ , bezeichnet als  $\mathbb{M}^+$ , lässt sich mit der Dulmage-Mendelsohn-Zerlegung finden [66, 152]. Ein Teilsystem  $\mathbb{M}$  ist genau dann *minimal strukturell überbestimmt* (Minimal-Structurally-Overdetermined, MSO), wenn es PSO ist und es eine strukturelle Redundanz von  $\varphi_s(\mathbb{M}) = 1$  besitzt. Ein Fehler  $f_i$  ist *strukturell detektierbar* in einem Modell  $\mathbb{M}$ , wenn  $e_{f_i} \in \mathbb{M}^+$  ist.  $e_{f_i}$  ist die Gleichung, die durch den Fehler  $f_i$  verletzt wird [82]. Ein Fehler  $f_i$  im Modell  $\mathbb{M}$  ist unter der Einzelfehlerannahme von einem Fehler  $f_j$  strukturell isolierbar, wenn  $f_j \in (\mathbb{M} \setminus \{e_{f_i}\})^+$  gilt [82]. Es ist zu beachten, dass die strukturelle Isolierbarkeit nur eine Näherung für die analytische Isolierbarkeit ist [154].

### 2.4.7 Kalman-Filter

Während Abschnitt 2.2 bereits die Offline-Parametrierung der Batteriemodelle eingeführt hat, befasst sich dieser Abschnitt mit der Online-Parameterschätzung. Um eine hohe Sensitivität der Fehlerdiagnose auch in Gegenwart von Alterung zu gewährleisten, ist es entscheidend, die Batteriezustände und -parameter zu schätzen. Das Kalman-Filter erweist sich als mächtiges Werkzeug, das Modellwissen mit Messdaten fusioniert, um Kenntnis über die aktuellen Zustände und Parameter zu erlangen. Das Filter geht auf Rudolph E. Kalman zurück, der in seiner Arbeit 1960 eine neue rekursive Lösung für das Problem der linearen Filterung diskreter Daten beschrieb [136]. Die nachfolgende Einführung basiert auf [30, 111, 190, 291].

Das Kalman-Filter beruht auf einem zweischrittigen Prinzip, das aus einer modellbasierten Prädiktion und einer anschließenden messungsbasierten Korrektur besteht. Das Filter ist in dem Sinne optimal, dass es die geschätzte Fehlerkovarianz minimiert - vorausgesetzt einige Bedingungen sind erfüllt. Obwohl diese notwendigen Bedingungen, die die nachfolgende Einführung aufführt, oftmals in den realen Anwendungen nicht uneingeschränkt gegeben sind, funktioniert das Filter in den meisten Fällen trotzdem gut. Die weite Verbreitung und der Erfolg des Filters lassen sich unter anderem auf diese Robustheit sowie die relative Einfachheit des Filters selbst zurückführen [291].

Das Ausgangsproblem, das das Kalman-Filter löst, ist die Schätzung des Zustands  $\mathbf{x} \in \mathbb{R}^n$  eines zeitdiskreten Systems, das durch die lineare stochastische Differenzgleichung

$$\mathbf{x}_k = \mathbf{A}\mathbf{x}_{k-1} + \mathbf{B}\mathbf{u}_k + \mathbf{w}_{k-1} \quad (2.48)$$

gegeben ist. Dabei setzt die Matrix  $\mathbf{A} \in \mathbb{R}^{n \times n}$  den Zustand  $\mathbf{x}_{k-1}$  des vorherigen Zeitschritts  $k - 1$  mit dem Zustand  $\mathbf{x}_k$  im aktuellen Schritt  $k$  in Beziehung. Die Matrix  $\mathbf{B} \in \mathbb{R}^{n \times l}$

ergänzt einen optionalen Systemeingang  $\mathbf{u}_k \in \mathbb{R}^l$  zum Zustand  $\mathbf{x}_k$ .  $\mathbf{w}_{k-1}$  repräsentiert das Prozessrauschen, welches als weißes Rauschen angenommen wird, das der Normalverteilung

$$p(\mathbf{w}) \sim \mathcal{N}(0, \mathbf{Q}) \quad (2.49)$$

mit der Prozess-Kovarianzmatrix  $\mathbf{Q}$  folgt. Zudem existieren Messungen  $\mathbf{z} \in \mathbb{R}^m$  mit

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k. \quad (2.50)$$

Dabei setzt die Matrix  $\mathbf{H}$  den Zustand  $\mathbf{x}$  mit den Messungen  $\mathbf{z}_k$  in Beziehung. Analog zum Prozessrauschen nimmt das lineare Filter für das Messrauschen weißes Rauschen mit der Normalverteilung

$$p(\mathbf{v}) \sim \mathcal{N}(0, \mathbf{R}) \quad (2.51)$$

an. Weiter basiert das Kalman-Filter auf der Annahme, dass  $\mathbf{w}$  und  $\mathbf{v}$  stochastisch unabhängig sind. Die Matrizen  $\mathbf{A}$ ,  $\mathbf{B}$  und  $\mathbf{H}$  aber auch  $\mathbf{Q}$  und  $\mathbf{R}$  können sich möglicherweise in jedem Zeitschritt ändern. Ändert sich beispielsweise die Kovarianzmatrix des Messrauschens oder des Systemrauschens signifikant, so bietet sich der Einsatz eines gleitenden Mittelwertfilters, ROSE-Filters oder einer Schätzung basierend auf der Maximum-Likelihood-Methode an [190]. Die System- und Rauschmatrizen werden an dieser Stelle aber vereinfachend als konstant angenommen.

Sei  $\hat{\mathbf{x}}_k^-$  die *a priori* Zustandsschätzung vor dem Schritt  $k$ , basierend auf dem Systemwissen nach Gleichung (2.48) und  $\hat{\mathbf{x}}_k$  die *a posteriori* Schätzung zum Schritt  $k$  nach Korrektur durch die Messung  $\mathbf{z}_k$  nach Gleichung (2.50). Dann lässt sich ein a priori Schätzfehler

$$\mathbf{e}_k^- = \mathbf{x}_k - \hat{\mathbf{x}}_k^- \quad (2.52)$$

und ein a posteriori Fehler

$$\mathbf{e}_k = \mathbf{x}_k - \hat{\mathbf{x}}_k \quad (2.53)$$

als Abweichung vom tatsächlichen (unbekannten) Zustand  $\mathbf{x}_k$  angeben. Daraus folgt die a priori geschätzte Fehlerkovarianz

$$\mathbf{P}_k^- = \mathbb{E}[\mathbf{e}_k^- \mathbf{e}_k^{-T}] \quad (2.54)$$

und die a posteriori geschätzte Fehlerkovarianz

$$\mathbf{P}_k = \mathbb{E}[\mathbf{e}_k \mathbf{e}_k^T]. \quad (2.55)$$

Mit dem Kalman-Filter soll nun die a posteriori Schätzung  $\hat{\mathbf{x}}_k$  ermittelt werden. Diese Schätzung basiert auf einer Linearkombination aus der a priori Schätzung  $\hat{\mathbf{x}}_k^-$  und dem

gewichteten Unterschied zwischen der eigentlichen Messung  $\mathbf{z}_k$  und einer Prädikation der Messung  $\mathbf{H}\hat{\mathbf{x}}_k^-$ :

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}(\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-). \quad (2.56)$$

Gleichung (2.56) gewährleistet, dass die ersten beiden Momente

$$\mathbb{E}[\mathbf{x}_k] = \hat{\mathbf{x}}_k \quad (2.57)$$

$$\mathbb{E}[(\mathbf{x}_k - \hat{\mathbf{x}}_k)(\mathbf{x}_k - \hat{\mathbf{x}}_k)^T] = \mathbb{E}[\mathbf{e}_k \mathbf{e}_k^T] = \mathbf{P}_k \quad (2.58)$$

der Zustandsverteilung beibehalten werden. Weitere Details zu den probabilistischen Ursprüngen des Filters und eine ausführlichere Herleitung liefert [30].

Der Ausdruck  $\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-$  entspricht dem Residuum, das auch als Messinnovation bezeichnet wird. Beim Residuum handelt es sich um die Abweichung zwischen der eigentlichen Messung und den aktuell prädizierten Messungen. Es gibt also an, wie *nahe* sich die aktuelle Schätzung und die tatsächlichen Messungen sind. In Gleichung (2.56) taucht die Matrix  $\mathbf{K} \in \mathbb{R}^{n \times m}$  auf, die als Kalman-Gain-Matrix bezeichnet wird. Die Matrix  $\mathbf{K}$  wird in jedem Schritt so gewählt, dass sie die a posteriori Fehler-Kovarianzmatrix  $\mathbf{P}_k$  (Gleichung (2.55)) minimiert. Dazu substituiert (2.56) die a posteriori Schätzung  $\hat{\mathbf{x}}_k$  in (2.53) für den a posteriori Fehler  $\mathbf{e}_k$  in (2.55). Eine Minimierung bezüglich dem Argument  $\mathbf{K}$  liefert die optimale Kalman-Gain-Matrix für den  $k$ -ten Zeitschritt [291]:

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}^T (\mathbf{H} \mathbf{P}_k^- \mathbf{H}^T + \mathbf{R})^{-1}. \quad (2.59)$$

Die vollständige Herleitung zeigt beispielsweise [190]. Eine weitere Interpretation des Kalman-Gains liefert die Betrachtung der beiden Grenzwerte  $\mathbf{R}_k \rightarrow 0$  und  $\mathbf{P}_k^- \rightarrow 0$ . Wird die Mess-Kovarianzmatrix  $\mathbf{R}$  sehr klein,

$$\lim_{\mathbf{R}_k \rightarrow 0} \mathbf{K}_k = \mathbf{H}^{-1}, \quad (2.60)$$

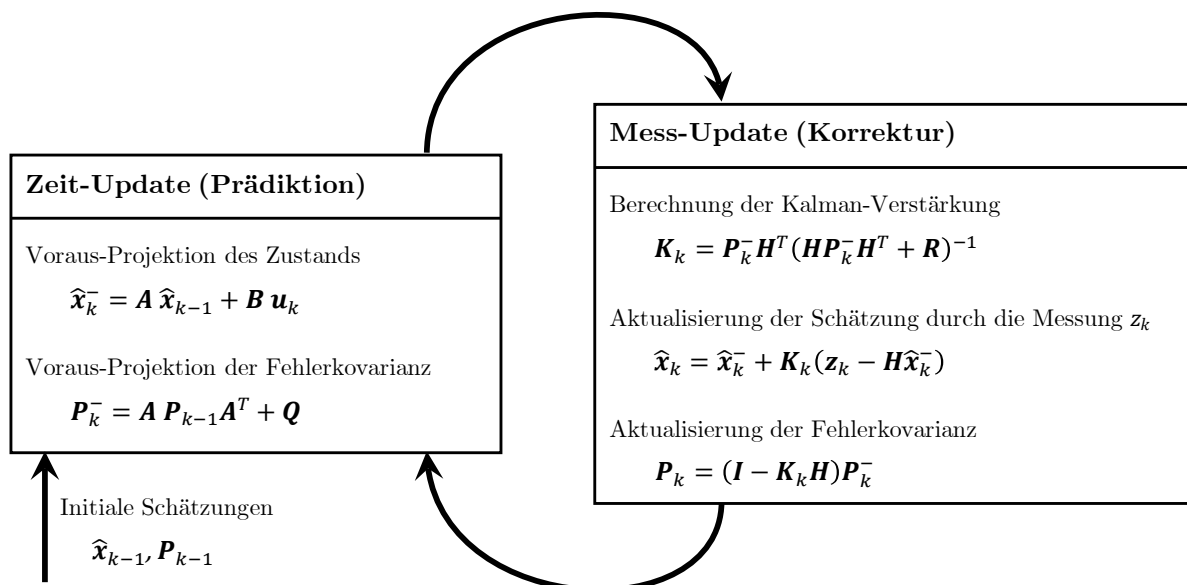
so werden die Residuen stärker gewichtet. Verkleinert sich umgekehrt die Prozess-Kovarianzmatrix

$$\lim_{\mathbf{P}_k^- \rightarrow 0} \mathbf{K}_k = \mathbf{0} \quad (2.61)$$

so verkleinert sich auch die Gewichtung der Residuen. Dies entspricht der Intuition, dass das Kalman-Filter im Falle größerer Messunsicherheit oder geringem Prozess-Rauschen das Modell stärker gewichtet und im Falle größerer Modellunsicherheit oder geringerem Messrauschen den Messungen stärker vertraut.

Abbildung 2.22 fasst das zweischrittige Prinzip des Kalman-Filters zusammen. Für jeden Zeitschritt  $k$  prädiziert das Filter zunächst basierend auf dem Systemmodell a priori den Zustand  $\hat{\mathbf{x}}_k^-$  und die Fehlerkovarianzmatrix  $\mathbf{P}_k^-$ . Im zweiten Schritt erfolgt basierend auf dem





**Abbildung 2.22:** Zusammenfassung des zweischrittigen Prinzips für das lineare Kalman-Filter.

berechneten Kalman-Gain  $\mathbf{K}_k$  a posteriori eine Korrektur des Systemzustands  $\hat{\mathbf{x}}_k$  und der Kovarianzmatrix  $\mathbf{P}_k$  des Fehlers. Die Initialisierung erfolgt mit einer anfänglichen Schätzung des Systemzustands  $\hat{\mathbf{x}}_{k-1}$  und der zugehörigen Kovarianzmatrix  $\mathbf{P}_{k-1}$ , die allgemein das Vertrauen in die Schätzung  $\hat{\mathbf{x}}_{k-1}$  angibt.

Abhängig von der zugrundeliegenden Anwendung können verschiedene Bedingungen, wie die Linearität des Systems oder eine mittelwertfreie Normalverteilung von Prozess- und Messrauschen, nur annähernd oder nicht erfüllt sein. Aus diesem Grund existiert in der bekannten Literatur eine Vielzahl an Erweiterungen des Standard-Kalman-Filters [182]. Auch die Anwendung auf Batterien erfordert aufgrund ihrer Nichtlinearität und Zeitvarianz eine Anpassung des Filters. Das Extended-Kalman-Filter (EKF) linearisiert beispielsweise die Systemmatrizen, basierend auf einer Taylor-Entwicklung, und eignet sich deshalb auch für nichtlineare Systeme. Einen Umgang mit stärkeren Nichtlinearitäten und zudem nicht-Gaußschen Systemen ermöglicht das Partikelfilter oder das in dieser Arbeit eingesetzte Sigma-Punkt-Kalman-Filter (SPKF) (siehe Abschnitt 5.5.2).



---

## 3 Matrix-Vektor-basierte Modellbildung für große Batteriepacks

Batteriemodelle ermöglichen die Vorhersage der messbaren Zellvariablen, wie Strom, Spannung und Temperatur für die Entwicklung und für die Überwachung während des Betriebs. Darüber hinaus ermöglicht das Modell einen optimierten Betrieb durch Zustandsschätzung und modellbasierte Fehlerdiagnose. Die Recheneffizienz des Modells ist entscheidend für die Entwicklung von Energiespeichersystemen, aber auch für Echtzeitanwendungen. Die Herausforderung sogenannter regelungsorientierter Modelle besteht darin, das Verhalten der einzelnen Zellen und die Wechselwirkungen mit den Nachbarzellen präzise abzubilden und dabei den Rechenaufwand gering zu halten. Basierend auf einer Untersuchung der bekannten Literatur (Abschnitt 3.1), stellt die vorliegende Arbeit ein neuartiges Framework für die elektro-thermische Modellierung von großen Batteriepacks vor. Der Ansatz berücksichtigt sowohl das individuelle Zellverhalten und die zyklische Alterung (Abschnitt 3.2) als auch die Wechselwirkungen zwischen benachbarten Zellen (Abschnitt 3.3). Die Parametrierung erfolgt anhand der zwei Zelltypen aus Tabelle 2.1, die über einen Temperaturbereich von 15 °C bis 45 °C und über den gesamten Ladezustandsbereich charakterisiert werden (Abschnitt 3.4). Drei Fehlerfälle im Batteriesystem, die das Modell-Framework korrekt abbildet, validieren das Modell. Aus den Ergebnissen lassen sich zudem fehlerspezifische Erkenntnisse zur modellbasierten und datengetriebenen Fehlerdiagnose ableiten (Abschnitt 3.5). Ein Batteriesystem, bestehend aus 500 Zellen, evaluiert die Modelleistung. Abschließend stellt Abschnitt 3.6 eine graphische Oberfläche vor, die sich zur übersichtlichen Darstellung der Systemzustände und zur Generierung einer Datenbasis für die darauffolgenden Fehlerdiagnosealgorithmen in den Kapiteln 4 und 5 eignet. Die Beiträge dieses Kapitels basieren auf der Veröffentlichung [245].

### 3.1 Stand der Technik

Die Vorteile recheneffizienter Modelle zeigen sich bereits in der Entwicklungsphase von Batteriesystemen. Modelle erlauben, verschiedene serielle und parallele Batteriekonfigurationen zu testen und das thermische Verhalten zu optimieren, indem der Einfluss der Kühlung untersucht wird. Auch für den Betrieb von großen Batteriespeichern eignen sich nur effiziente Modelle, da ein hoher Rechenaufwand die Hardwarekosten steigert, die Energieeffizienz des

Energiespeichers verringert und einen Echtzeiteinsatz erschwert. Einige Modellansätze für Batteriepacks betrachten die gesamte Batterie als eine große Zelle [254, 261]. Dies erlaubt zwar eine Simulation der gesamten Batterie mit geringem Rechenaufwand, vernachlässigt aber alle Parametervariationen sowie die Strom- und Temperaturverteilung zwischen den Zellen. Diese Vereinfachung kann zur Überladung von Zellen führen, was einer der möglichen Auslöser für ein thermisches Durchgehen ist [125]. Die Notwendigkeit der Berücksichtigung des Einzelzellenverhaltens bestätigen auch Rolt, Douglas u. a., die in ihrer Arbeit ein elektrisches Modell für einen Batteriepack vorstellen [228]. Da sich selbst Zellen der gleichen Zellchemie und der gleichen Charge nicht identisch verhalten, müssen Parametervariationen berücksichtigt werden [252]. Es existieren sehr viele wissenschaftliche Veröffentlichungen zur elektrischen und thermischen Modellierung von unverbundenen Lithium-Ionen-Einzelzellen und immer mehr Literatur zu Parametervariationen. Die effiziente Modellierung von Wechselwirkungen im Batteriesystem wird jedoch nur selten behandelt, obwohl dies ein wichtiges Thema in großen Batteriepacks ist [97, 308]. Die Herausforderung von effizienten Ansätzen besteht darin, das Verhalten der einzelnen Zellen möglichst genau abzubilden und dabei die Rechenkomplexität gering zu halten. Dubarry, Vuillaume und Liaw berücksichtigen in ihrem Modell das individuelle Verhalten aller Zellen und stellen in einer späteren Arbeit die veröffentlichten Teilmodelle zu einem ganzheitlichen Framework zusammen [61, 64]. Das Framework enthält jedoch kein thermisches Modell und der Rechenaufwand ist insbesondere für parallel geschaltete Zellen sehr hoch. Um die Wechselwirkungen von parallel geschalteten Zellen zu untersuchen, wurden bereits Modelle für die Stromverteilung eingeführt. Yang, Zhang u. a. stellen ein thermisch-elektrochemisches Modell vor, um die ungleichmäßige Entladung und Alterung aufgrund von Temperaturunterschieden zwischen parallel geschalteten Zellen zu untersuchen [308]. Pastor-Fernández, Bruen u. a. messen die Ströme für parallel geschaltete Zellen, um die Konvergenz der Alterung ausgehend von anfänglichen Unterschieden im SOH zu untersuchen [213]. Um die zellindividuellen Ströme von parallelgeschalteten Zellen in Anwesenheit von Parameterunterschieden zu untersuchen, stellen Bruen und Marco ein Zustandsraummodell für die Stromverteilung vor [23]. Die genannten Studien beschränken sich jedoch auf das elektrische Verhalten und berücksichtigen keine thermischen Wechselwirkungen zwischen den Zellen. Xie, Li u. a. unterteilen eine zylindrische Lithium-Ionen-Zelle in ein parallel geschaltetes Zellnetzwerk [301]. Die Arbeit konzentriert sich auf die elektrische und thermische Modellierung innerhalb der Zelle. Guo, Ramaswamy u. a. modellieren in ihrer Arbeit ein 4s3p-Modul, jedoch auch ohne Einbeziehung eines thermischen Modells [100]. Für die Zustandsschätzung in rekonfigurierbaren Batteriesystemen präsentieren Couto und Kinnaert ein elektrochemisches Modell reduzierter Ordnung [44]. Cordoba-Arenas, Onori und Rizzoni entwickeln ein effizientes Modell mit Fokus auf das zyklische Alterungsverhalten des gesamten Packs für Plug-in-Hybridfahrzeuge (Plug-in-Hybrid-Electric-Vehicles, PHEVs) [42]. Um eine ausreichende Performance zu erreichen, besitzen die Zellen jedoch keine SOC- und temperaturabhängigen Parameter.

## 3.2 Elektro-thermische Modellierung der Zelle

Um ein ganzheitliches Modell einer Lithium-Ionen-Zelle zu erhalten, modelliert diese Arbeit das elektrische (Abschnitt 3.2.1), das thermische (Abschnitt 3.2.2) und das Alterungsverhalten (Abschnitt 3.2.3). Eine Co-Simulation des elektrischen, thermischen und Alterungsmodells ermöglicht es, eine Zelle über ihren Lebenszyklus zu beschreiben [94].

### 3.2.1 Elektrisches Modell

Je nach Detailgrad innerhalb der Zelle und dem Fokus der Modellierung kommen elektrochemische Modelle, empirische Modelle, datengetriebene Modelle oder elektrische Ersatzschaltbildmodelle zum Einsatz [197, 270, 317]. Der nachfolgende Abschnitt untersucht die Anwendbarkeit dieser Modellansätze. Anschließend stellt dieser Abschnitt die Modellgleichungen und die Implementierung des gewählten Ersatzschaltbildmodells vor.

#### Modellwahl

*Elektrochemische Modelle* beschreiben das Verhalten einer Lithium-Ionen-Zelle auf einer mikroskopischen Ebene. Da elektrochemische Modelle eine Beziehung zwischen mikroskopischen Größen und messbaren Variablen der Zelle herstellen, gehören die Modelle zu den genauesten Batteriemodellen. Sie sind geeignet, um andere Modelle zu validieren [80, 94]. Allerdings führt die hohe Genauigkeit und die daraus resultierende Komplexität zu einem großen Speicherbedarf und experimentellen Aufwand sowie einer langen Rechenzeit für die Parametrierung und Simulation dieser Modelle. Obwohl Anstrengungen unternommen wurden, die Rechenkomplexität elektrochemischer Modelle zu reduzieren [36, 55, 267], sind sie für die Überwachung eines großen Batteriesystems in Echtzeit auf heutigen Mikrocontrollern noch nicht anwendbar [273].

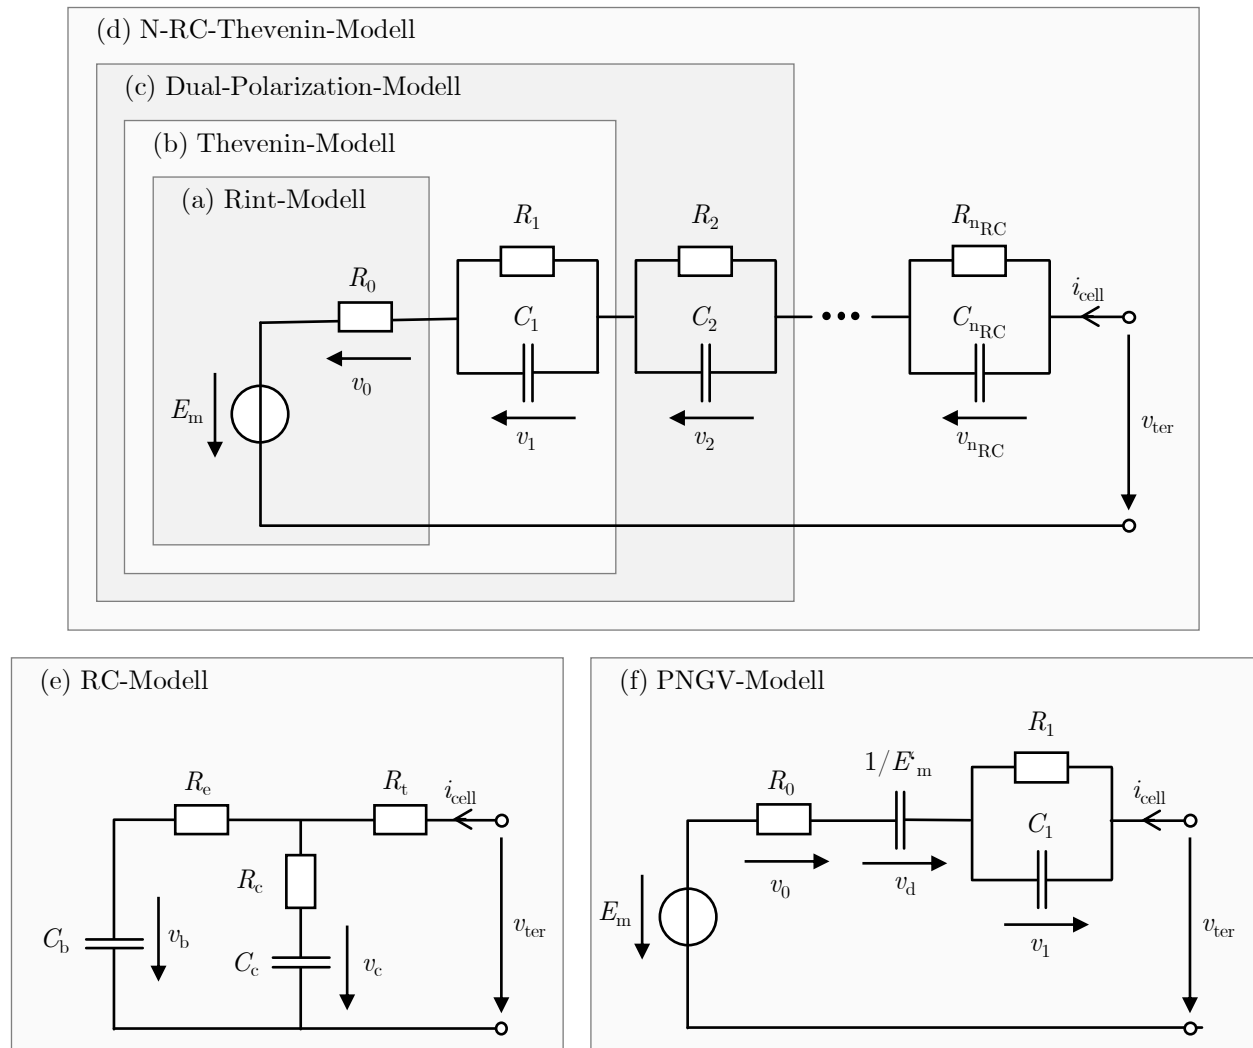
*Empirische Modelle* erlauben, das Verhalten einer Batteriezelle auf der Systemebene auf analytische oder stochastische Weise zu beschreiben. Die Modelle verwenden empirische Gleichungen, die auf physikalischen Gesetzmäßigkeiten basieren. Prominente Beispiele für empirische Modelle in der Literatur sind das Shepherd-Modell [281] und das Nernst-Modell [72]. Manwell und McGowan stellen ein kinetisches Batteriemodell vor, das die gesamte Batterieladung durch ein Zwei-Tank-System modelliert [189]. Stochastische Modelle basieren meist auf mehrdimensionalen zeitdiskreten Markov-Prozessen [80]. Die mathematischen Modelle sind in der Regel in einer effizienten Art und Weise genau auf die gewünschte Anwendung ausgelegt. Die Ansätze liefern Informationen über die Lebensdauer, Effizienz oder Kapazität einer Zelle in einer spezifischen Anwendung [273]. Aufgrund der vielen Vereinfachungen können die Modelle jedoch schnell an Genauigkeit verlieren und es ist herausfordernd, hochdynamische Effekte abzubilden [28].

Basierend auf Eingangs- und Ausgangs-Daten ermöglichen *datengetriebene Modelle* eine

Black-Box-Beschreibung der Zelle ohne zusätzliches Vorwissen über elektrochemische Zusammenhänge. Die Eingangsdaten im Training sind in der Regel der Strom und zusätzliche beschreibende Zustände, wie beispielsweise der SOC oder die Temperatur. Den Ausgang bildet die Klemmenspannung der Zelle. In der Literatur finden Methoden aus dem Bereich des maschinellen Lernens, wie künstliche neuronale Netze [26], Support-Vector-Machines (SVMs) [196] oder Extreme-Learning-Machines [60] Anwendung [197]. Liegt ein Datensatz vor, der den gesamten Betriebsbereich abdeckt, sind datengetriebene Modelle in der Lage, die Klemmenspannung der Batterie vorherzusagen. Die maschinellen Lernverfahren sind jedoch schlecht geeignet, um das Verhalten der Zelle außerhalb des trainierten Betriebsbereichs hinsichtlich des Stroms, des SOCs und der Temperatur zu extrapolieren.

*Elektrische Ersatzschaltbildmodelle* (Electrical-equivalent-Circuit-Models, ECMs) beschreiben das Verhalten einer Lithium-Ionen-Zelle durch eine Kombination von elektrischen Komponenten wie Spannungsquellen, Widerständen, Kondensatoren oder Spulen [270]. Die Verbindung dieser Elemente zu einer elektrischen Ersatzschaltung bildet das dynamische Verhalten einer Zelle mit nur wenigen Parametern nach. Typische Modelle für Fahrzeugbatterien sind das Innenwiderstandsmodell (Rint-Modell), das Widerstands-Kapazitätsmodell (RC-Modell), das Thevenin-Modell und das PNGV-Modell (Abbildung 3.1). Eine Übersicht und einen Vergleich der elektrischen Batteriemodelle finden sich in [114, 126, 130, 131, 287]. Das Rint-Modell beschreibt die Batterie als eine ideale Spannungsquelle  $E_m$  in Reihe mit einem Innenwiderstand  $R_0$  (Abbildung 3.1a). Aufgeteilt in Bulk- und Oberflächenkapazität, besteht die Struktur des RC-Modells aus zwei parallel geschalteten Kondensatoren (Abbildung 3.1e). Der Bulk-Kondensator  $C_b$  mit einer großen Kapazität repräsentiert die Fähigkeit einer Batterie, Ladung chemisch zu speichern, während der kleine Oberflächenkondensator  $C_c$  die dynamischen Oberflächeneffekte einer Batterie modelliert [114]. Die Struktur des Thevenin-Modells fügt dem Widerstand des Rint-Modells ein RC-Glied in Reihe hinzu, um die Polarisation zu berücksichtigen (Abbildung 3.1b). Eine Erweiterung des Thevenin-Modells bildet das Doppelpolarisationsmodell (DP-Modell) (Abbildung 3.1c), das einem Thevenin-Modell mit einer Anzahl von  $n_{RC} = 2$  RC-Elementen entspricht. Die beiden RC-Elemente korrespondieren mit elektrochemischen Prozessen der galvanischen Zelle. Das erste RC-Element entspricht der elektrochemischen Polarisation; das zweite entspricht der Konzentrationspolarisation der Zelle. In der Literatur hat sich das DP-Modell als guter Kompromiss zwischen Komplexität und Genauigkeit erwiesen [39, 114]. Es gibt auch Varianten mit drei RC-Elementen [233] oder einer Anzahl von  $n_{RC}$  RC-Elementen [108, 124], die die Genauigkeit weiter verbessern können (Abbildung 3.1d). Mit der Anzahl der RC-Elemente steigt jedoch der Parametrierungs- und Rechenaufwand. Das PNGV-Modell (Partnership-for-New-Generation-of-Vehicles) ist eine Erweiterung des Thevenin-Modells (Abbildung 3.1f). Ein zusätzlicher Kondensator  $1/E'_m$  in Reihe zum Innenwiderstand  $R_0$  beschreibt die Änderung der OCV aufgrund der zeitlichen Akkumulation des Laststroms.

Da ECMs ein gutes Gleichgewicht zwischen Genauigkeit und Rechenaufwand zeigen,



**Abbildung 3.1:** Typische elektrische Ersatzschaltbildmodelle für Fahrzeugbatterien: (a) Rint-Modell, (b) Thevenin-Modell, (c) DP-Modell, (d) N-RC-Thevenin-Modell, (e) RC-Modell und (f) PNGV-Modell.

verwendet sie auch das nachfolgende Modell-Framework. Nach der Parametrierung eines Ersatzschaltbildmodells ist es möglich, dieses auf einem Mikrocontroller zu betreiben und das Verhalten der Batterie in Echtzeit vorherzusagen [121, 273]. Die Parameter eines ECMs sind jedoch erheblich von den Betriebsbedingungen wie Strom, Temperatur, SOC und SOH der Zelle abhängig (siehe Abschnitt 2.2.3). Für eine hohe Genauigkeit muss die Parametrierung deshalb über den gesamten Betriebsbereich erfolgen. Zudem ist eine Parametrierung abhängig von den Betriebsbedingungen erforderlich.

### Modellgleichungen und Implementierung des elektrischen Zellmodells

Die Basis des elektrischen Zellmodells bildet das N-RC-Thevenin-Modell aus Abbildung 3.1d. Je nach Parametrisierung ist es durch Vereinfachung der Modellstruktur auch in der Lage, das DP-, Thevenin- und Rint-Modell abzubilden (Abbildung 3.1a-c). Das elektrische Modell

wird mit einem anfänglichen Entladungsgrad

$$\mathbf{DOD}(0) = \mathbf{\Delta}_{\text{DOD}}(\sigma_{\text{DOD}}) \cdot \overline{\text{DOD}} \in \mathbb{R}^{n_{\text{cell}}} \quad (3.62)$$

initialisiert, wobei ein mittlerer DOD von  $\overline{\text{DOD}}$  und eine anfängliche Variation von  $\mathbf{\Delta}_{\text{DOD}}(\sigma_{\text{DOD}})$  zwischen den Zellen angenommen wird. Fettgedruckte Größen entsprechen Vektoren oder Matrizen. Die Berechnung des Variationsvektors  $\mathbf{\Delta}_{\text{DOD}}(\sigma_{\text{DOD}}) \in \mathbb{R}^{n_{\text{cell}}}$  mit der Standardabweichung  $\sigma_{\text{DOD}}$  stellt Abschnitt 3.3.3 vor. Die gemäß (3.144) berechneten Faktoren ermöglichen die effiziente Initialisierung aller  $n_{\text{cell}}$  Zellen. Die anfänglichen Zellkerntemperaturen

$$\mathbf{T}_c(0) = \mathbf{\Delta}_{\text{T}_c}(\sigma_{\text{T}_c}) \cdot \overline{T}_c \in \mathbb{R}^{n_{\text{cell}}} \quad (3.63)$$

mit dem Variationsvektoren  $\mathbf{\Delta}_{\text{T}_c}(\sigma_{\text{T}_c}) \in \mathbb{R}^{n_{\text{cell}}}$  variieren analog um die mittlere Kerntemperatur  $\overline{T}_c$ . Die Lösung der Differentialgleichung

$$\mathbf{D}\dot{\mathbf{O}}\mathbf{D}(t) = \mathbf{i}_{\text{cell}}(t) \quad (3.64)$$

für die Coulomb-Zählung mit der Trapezregel liefert für eine Schrittweite  $h$  und  $t_k = t_0 + kh$  den Zusammenhang

$$\mathbf{DOD}[k+1] = \mathbf{DOD}[k] + \frac{h}{2}(\mathbf{i}_{\text{cell}}[k] + \mathbf{i}_{\text{cell}}[k+1]). \quad (3.65)$$

Dieses Kapitel notiert kontinuierliche Größen mit runden Klammern und zeitdiskrete Größen mit eckigen Klammern:  $\mathbf{DOD}[k] := \mathbf{DOD}(t_k)$ . Der Vektor  $\mathbf{i}_{\text{cell}}$  beinhaltet alle Einzelzellströme. Die Kapazität zum Zeitschritt  $k$  ist gegeben durch

$$\mathbf{Q}[k] = \mathbf{SOH}_Q[k] \circ \mathbf{\Delta}_Q(\sigma_Q) \cdot \overline{Q}, \quad (3.66)$$

mit dem SOH-Vektor  $\mathbf{SOH}_Q$ , der aus dem Alterungsmodell (Abschnitt 3.2.3) resultiert, dem Parameter-Variationsvektor  $\mathbf{\Delta}_Q(\sigma_Q) \in \mathbb{R}^{n_{\text{cell}}}$  und der mittleren Zellkapazität  $\overline{Q}$ . Eckige Klammern kennzeichnen neben zeitdiskreten Werten die elementweise Anwendung einer Funktion  $f(\cdot)$  auf eine Matrix  $\mathbf{A} = [a_{ij}]$ ,  $f[\mathbf{A}] := [f(a_{ij})]$ . Der  $\circ$ -Operator entspricht dem Hadamard-Produkt, das als elementweises Produkt  $\mathbf{A} \circ \mathbf{B} := [a_{ij}b_{ij}]$  zweier Matrizen  $\mathbf{A}$  und  $\mathbf{B} = [b_{ij}]$  definiert ist. Analog kennzeichnet der  $\oslash$ -Operator die Hadamard-Division  $\mathbf{A} \oslash \mathbf{B} := [a_{ij}/b_{ij}]$ . Der Exponent  $(\cdot)^{op}$  entspricht der Hadamard-Potenz  $\mathbf{A}^{op} := [a_{ij}^p]$ , die als elementweise Potenz der Matrix definiert ist. Der aktuelle SOC folgt durch

$$\mathbf{SOC}[k] = \mathbf{1}_{n_{\text{cell}}} + \mathbf{DOD}[k] \circ \mathbf{Q}^{\circ-1}[k]. \quad (3.67)$$



Dabei entspricht  $\mathbf{1}_{n_{\text{cell}}} := [1 \dots 1]^T \in \mathbb{R}^{n_{\text{cell}}}$  dem  $n_{\text{cell}}$ -dimensionalen Eins-Vektor. Die Definitionen von DOD in der Einheit Ah und SOC in Prozent orientieren sich an [4]. Ausgehend von der Kerntemperatur  $T_{c,i}[k]$  und dem SOC jeder Zelle  $\text{SOC}_i[k]$ ,  $i \in [1, n_{\text{cell}}]$  erfolgt nachfolgend die Berechnung der elektromotorischen Kraft  $E_{m,i}$ , des Ohmschen Spannungsabfalls  $v_{0,i}$  und der Polarisationsspannungen  $v_{1 \dots n_{\text{RC}},i}$  der  $n_{\text{RC}}$  RC-Glieder. Die Größen summieren sich zu der Klemmenspannung  $v_{\text{ter},i}$  für das N-RC-Thevenin-Modell (Abbildung 3.1d). Die elektromotorische Kraft  $\mathbf{E}_m[k] \in \mathbb{R}^{n_{\text{cell}}}$ , die der OCV der Zellen entspricht, berechnet sich nach

$$\mathbf{E}_m[k] = \mathcal{E}_m[\text{SOC}[k], \mathbf{T}_c[k]] \quad (3.68)$$

mit der Wertetabelle  $\mathcal{E}_m: \mathbb{R}^2 \rightarrow \mathbb{R}$ . Die OCV zeigt zudem eine Abhängigkeit vom SOH der Zellen [141, 292]. Dieser Effekt, der bislang nicht im Modell berücksichtigt ist, ließe sich über eine Parametrisierung von  $\mathbf{E}_m[k]$  mit einer Wertetabelle  $\mathcal{E}_m[\text{SOC}[k], \mathbf{T}_c[k], \text{SOH}[k]]$ ,  $\mathcal{E}_m: \mathbb{R}^3 \rightarrow \mathbb{R}$  abbilden. Die Ohmschen Widerstände  $\mathbf{R}_0 \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{cell}}}$  berechnen sich nach

$$\mathbf{R}_0[k] = \text{SOH}_R[k] \circ \Delta_{R_0}(\sigma_{R_0}) \circ \mathcal{R}_0[\text{SOC}[k], \mathbf{T}_c[k]] \quad (3.69)$$

mit dem SOH-Vektor  $\text{SOH}_R$  aus dem Widerstandserhöhungsmodell (Abschnitt 3.2.3) und der Wertetabelle des internen Widerstands  $\mathcal{R}_0: \mathbb{R}^2 \rightarrow \mathbb{R}$ . Der Ohmsche Spannungsabfall für jede Zelle folgt gemäß

$$\mathbf{v}_0[k] = \mathbf{R}_0[k] \circ \mathbf{i}_{\text{cell}}[k] \quad (3.70)$$

mit dem Vektor der Zellströme  $\mathbf{i}_{\text{cell}}[k] \in \mathbb{R}^{n_{\text{cell}}}$  zum Zeitschritt  $k$ . Für eine Anzahl von  $n_{\text{RC}}$  RC-Gliedern erfolgt die Bestimmung der Polarisationswiderstände  $\mathbf{R}_p[k] \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{RC}}}$  und Polarisationskapazitäten  $\mathbf{C}_p[k] \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{RC}}}$  durch

$$\mathbf{R}_p[k] = \text{SOH}_R[k] \circ \Delta_{R_p}(\sigma_{R_p}) \mathbf{1}_{n_{\text{RC}}}^T \circ \mathcal{R}_p[\text{SOC}[k], \mathbf{T}_c[k]] \quad (3.71)$$

$$\mathbf{C}_p[k] = \Delta_{C_p}(\sigma_{C_p}) \mathbf{1}_{n_{\text{RC}}}^T \circ \mathcal{C}_p[\text{SOC}[k], \mathbf{T}_c[k]], \quad (3.72)$$

wobei  $\mathcal{R}_p: \mathbb{R}^2 \rightarrow \mathbb{R}^{1 \times n_{\text{RC}}}$  und  $\mathcal{C}_p: \mathbb{R}^2 \rightarrow \mathbb{R}^{1 \times n_{\text{RC}}}$  die zugehörigen Wertetabellen für die Matrizen  $\mathbf{R}_p$  und  $\mathbf{C}_p$  sind. Die  $n_{\text{RC}}$  Zeitkonstanten für die RC-Glieder sind durch die Matrix

$$\boldsymbol{\tau}_p[k] = \mathbf{R}_p[k] \circ \mathbf{C}_p[k] \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{RC}}} \quad (3.73)$$

gegeben. Die bestimmenden Differentialgleichungen für die Polarisationsspannungen  $\mathbf{v}_p \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{RC}}}$  in kontinuierlicher Zeit sind

$$\dot{\mathbf{v}}_p(t) = \underbrace{-\boldsymbol{\tau}_p^{-1}(t) \circ \mathbf{v}_p(t) + \mathbf{C}_p^{-1}(t) \circ \mathbf{i}_{\text{cell}}(t) \cdot \mathbf{1}_{n_{\text{RC}}}^T}_{f_p[t, \mathbf{v}_p(t)]} \quad (3.74)$$

Eine Diskretisierung von  $f_p [t, \mathbf{v}_p(t)]$  führt zu

$$f_p [k, \mathbf{v}_p[k]] = -\boldsymbol{\tau}_p^{\circ-1}[k] \circ \mathbf{v}_p[k] + \mathbf{C}_p^{\circ-1}[k] \circ \mathbf{i}_{\text{cell}}[k] \cdot \mathbf{1}_{n_{\text{RC}}}^T. \quad (3.75)$$

Die Lösung von (3.74) mit der Euler-Methode ergibt

$$\mathbf{v}_p[k+1] = \mathbf{v}_p[k] + hf_p [k, \mathbf{v}_p[k]]. \quad (3.76)$$

Zur Verbesserung der Simulationsgenauigkeit bei vertretbarem Rechenaufwand verwendet das Modell die explizite Mittelpunktmethode

$$\mathbf{v}_p[k+1] = \mathbf{v}_p[k] + hf_p \left[ k + \frac{h}{2}, \mathbf{v}_p[k] + \frac{h}{2} f_p [k, \mathbf{v}_p[k]] \right] \quad (3.77)$$

zur Integration. Größere Schrittweiten als die in Abschnitt 3.5.4 gewählten oder kleinere Zeitkonstanten als die in Abschnitt 3.5.1 identifizierten, können Runge-Kutta-Verfahren höherer Ordnung oder erweiterte numerische Integrationsverfahren erfordern [106]. Der gesamte Polarisationsspannungsabfall berechnet sich gemäß

$$\mathbf{v}_{\text{pol}}[k] = \sum_{j=1}^{n_{\text{RC}}} \mathbf{v}_{p,j}[k] \quad (3.78)$$

mit  $\mathbf{v}_p = [\mathbf{v}_{p,1} \ \mathbf{v}_{p,2} \ \dots \ \mathbf{v}_{p,n_{\text{RC}}}]$ . Für die Berechnung der Stromverteilung in Abschnitt 3.3.1 wird zudem die Spannung

$$\mathbf{v}_{\Sigma}[k] = \mathbf{E}_m[k] + \mathbf{v}_{\text{pol}}[k] \quad (3.79)$$

definiert. Die Klemmenspannungen der Zellen

$$\mathbf{v}_{\text{ter}}[k] = \mathbf{E}_m[k] + \mathbf{v}_0[k] + \mathbf{v}_{\text{pol}}[k] \quad (3.80)$$

zum Zeitschritt  $k$  setzen sich aus der OCV  $\mathbf{E}_m[k]$ , dem Ohmschen Spannungsabfall  $\mathbf{v}_0[k]$  und der Polarisationsspannung  $\mathbf{v}_{\text{pol}}[k]$  zusammen.

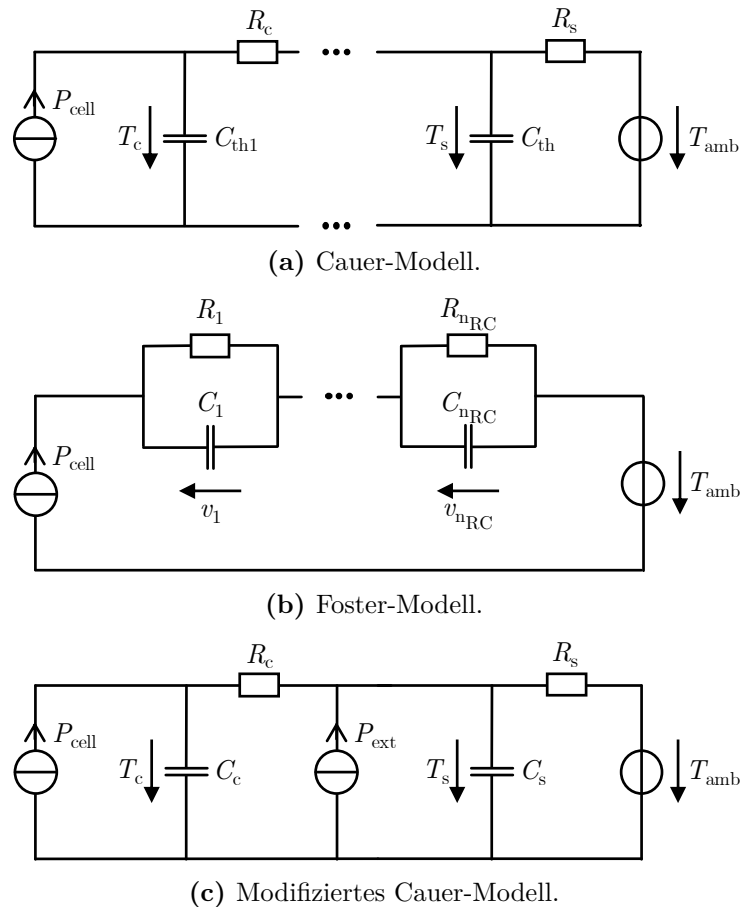
### 3.2.2 Thermisches Modell

Die Kenntnis der internen Zelltemperatur spielt eine wichtige Rolle für die Modellierung des Zellverhaltens, da die Temperatur die physikalischen und chemischen Prozesse innerhalb der Zelle stark beeinflusst. Thermische Modelle erlauben zudem die Entwicklung effizienter Kühlstrategien [287] und thermisch verbesserter Designs [9, 310]. Der nachfolgende Abschnitt geht auf verschiedene Modellansätze ein, bevor die Modellgleichungen und die Implementierung des thermischen Zellmodells gezeigt werden.

## Modellwahl

Die verschiedenen Ansätze aus der Literatur zur thermischen Modellierung unterscheiden sich vor allem in ihrer Komplexität und ihrer räumlichen Auflösung [94]. Thermische Modelle mit räumlicher Auflösung sind in der Regel rechenintensiv [269] und die genaue innere Struktur und Materialien der Zelle müssen bekannt sein [314]. Zudem hat das Zellformat (prismatisch [212], Pouch [96], zylindrisch [221]) einen entschiedenen Einfluss auf die Modellierung. Für die recheneffiziente Modellierung der Temperatur, in Kombination mit einem elektrischen Zellmodell, sind Ansätze mit geringerer Komplexität und ohne räumliche Auflösung vorteilhaft. Hu, Liu u. a. vergleichen in einer umfassenden Studie recheneffiziente thermische Modelle [122]. Unter der Annahme einer konzentrierten thermischen Dynamik beschreiben thermische Ersatzschaltbildmodelle den thermischen Wärmeübergangsprozess mit einer hohen Genauigkeit [110]. Die Ersatzschaltbildmodelle stellen die thermischen Größen, Wärmestrom und Temperatur, durch die elektrischen Größen, Strom und Spannung, dar. Kondensatoren repräsentieren Wärmespeicher und Widerstände verkörpern konduktive, konvektive oder strahlende Wärmeübertragungsphänomene. Eine Stromquelle stellt die Wärmegenerierung dar und eine Spannungsquelle dient als thermisches Potential der Umgebung.

Die thermischen Ersatzschaltbildmodelle lassen sich in zwei Klassen unterteilen: *Cauer-Modelle* und *Foster-Modelle* (Abbildung 5.3). Letzteres setzt sich, ähnlich den ECMs, aus der Reihenschaltung eines oder mehrerer RC-Elemente zusammen [120]. Der Wärmestrom der RC-Elemente ist, bedingt durch die Serienschaltung, identisch. Somit ist das Foster-Modell nur in der Lage, den aus der Verlustleistung der Zelle resultierenden Wärmetransport zu modellieren. Zudem ist aufgrund des unendlich hohen Widerstands der Stromquelle  $P_{\text{cell}}$  eine Modellierung des resultierenden dynamischen Systemverhaltens nach einer Änderung der Umgebungstemperatur nicht möglich [94]. Ein mathematisch komplexeres Modell ist das *Cauer-Modell*. Es ist in der Lage, den Wärmestrom basierend auf der Außentemperatur und der Verlustleistung der Zelle zu modellieren. Allerdings ist der analytische Rechenaufwand zur Bestimmung der Wärmeverteilung höher als beim Foster-Modell [94]. Dies liegt daran, dass die Temperatur an jedem Knoten des Modells sowohl von der Wärme der anderen Knoten als auch von der Wärmeübertragung zwischen den Knoten abhängt. Das Cauer-Modell besteht aus einer oder mehreren thermischen Kapazitäten und Widerständen, die je nach angestrebter Systemordnung kaskadierbar sind. Die thermischen Kapazitäten modellieren die Wärmekapazität der verschiedenen Segmente des Systems. Die thermischen Widerstände beschreiben den Wärmeübergang zwischen zwei Segmenten. Lin, Perez u. a. verwenden ein Cauer-Modell, um die Kerntemperatur für zylindrische Zellen zu schätzen [168]. Die Parametrisierung eines elektrothermischen Modells auf Basis der Cauer-Struktur führen Lin, Perez u. a. für zylindrische Zellen und Firouz, Omar u. a. für prismatische Lithium-Ionen-Kondensatoren durch [78, 167]. Orcioni, Buccolini u. a. wenden ein Cauer-Modell innerhalb einer Simulationsumgebung für Batteriepacks an [209].



**Abbildung 3.2:** Thermische Zellmodelle, die für die Echtzeitmodellierung geeignet sind: (a) Cauer-Modell, (b) Foster-Modell und (c) ein modifiziertes Cauer-Modell, das den Wärmeeintrag an der Zelloberfläche berücksichtigt.

Aufgrund eines günstigen Kompromisses zwischen Genauigkeit, Flexibilität und Berechnungsaufwand implementiert diese Arbeit eine modifizierte Version des Cauer-Modells, das das thermische Verhalten einer Zelle beschreibt. Um die externen Wärmeeinträge in die Zelle zu berücksichtigen, besitzt das Modell eine zusätzliche Wärmequelle auf der Oberfläche der Zelle (Abbildung 5.3c). Die externen Wärmeeinträge resultieren aus den benachbarten Zellen, der Kühlung und der Ohmschen Wärmegenerierung an den Kontakten und in den Stromschienen, siehe Abschnitt 3.3.2. Für rekonfigurierbare Batteriesysteme kommt die Wärmegenerierung der Elektronik hinzu. Um eine zellindividuelle Simulation zu ermöglichen, berücksichtigt das Modell auch Parametervariationen der Kontakt- und Stromschienenwiderstände.

### Modellgleichungen und Implementierung des thermischen Zellmodells

Nach Thomas und Newman sowie Lin, Perez u. a. lässt sich die Wärmegenerierung in einer Lithium-Ionen-Batterie in einen irreversiblen und einen reversiblen Teil aufteilen [167, 275]. Die irreversible Wärmegenerierung resultiert aus der Ohmschen Erwärmung und berechnet

sich gemäß

$$\mathbf{P}_{\text{res}}[k] = \mathbf{R}_0[k] \circ \mathbf{i}_{\text{cell}}^2[k] + \mathbf{v}_p[k] \circ \mathbf{i}_{\text{cell}}[k]. \quad (3.81)$$

Die reversible Wärmegenerierung hat unterschiedliche Ursprünge. Der Dominanteste ist die entropische Wärme, die auf der Entropieänderung der Zellreaktion beruht. Insbesondere bei niedrigen Stromraten liegen die entropischen Wärmeeinflüsse in der gleichen Größenordnung wie die resistive Wärmegenerierung [287]. Die entropische Wärmegenerierung ist gegeben durch

$$\mathbf{P}_{\text{entr}}[k] = c_{\text{entr}} [\mathbf{SOC}[k]] \circ \mathbf{T}_c[k] \circ \mathbf{i}_{\text{cell}}[k] \quad (3.82)$$

mit dem SOC-abhängigen entropischen Wärmekoeffizienten  $c_{\text{entr}} = \partial E_m / \partial T_c$ . Weitere reversible Wärmequellen, wie die durch zusätzliche chemische Reaktionen erzeugte Wärme oder die Mischungswärme, die auf die Bildung und Relaxation von Konzentrationsgradienten innerhalb der Zelle zurückzuführen ist, vernachlässigt das Modell, da ihr Einfluss auf die gesamte Wärmegenerierung gering ist [79, 275]. Die gesamte Wärmegenerierung innerhalb der Zelle summiert sich zu

$$\mathbf{P}_{\text{cell}}[k] = \mathbf{P}_{\text{res}}[k] + \mathbf{P}_{\text{entr}}[k]. \quad (3.83)$$

Das für jede Zelle verwendete thermische Modell ist ein Cauer-Modell [79, 167], das für das Modell-Framework um die externe Wärmegenerierung  $P_{\text{ext}}$  gemäß Abbildung 3.2c ergänzt wird. Die Quelle  $P_{\text{cell}}$  erwärmt die thermische Kapazität des Kerns  $C_c$ . Ein thermischer Widerstand  $R_c$  verbindet die Kernkapazität  $C_c$  mit dem Oberflächenpotential  $T_s$ . Zudem speist die Wärmequelle  $P_{\text{ext}}$  die Oberflächenkapazität  $C_s$ , was einem externen Wärmeeintrag entspricht. Die Wärmegenerierung resultiert aus der Jouleschen Erwärmung der Kontaktwiderstände, möglicher Elektronik und Stromschienen, die die Zellen miteinander verbinden. Hinzu kommt der Einfluss der benachbarten Zellen, die je nach ihrer Oberflächentemperatur einen positiven oder negativen Wärmestrom hinzufügen. Die Oberfläche der Zelle ist über den Widerstand  $R_{\text{amb}}$  mit dem thermischen Potential der Umgebung  $T_s$  verbunden. Ist die Zelle an eine aktive Kühlung angeschlossen, entspricht  $T_{\text{amb}}$  der Temperatur der Kühlung und  $R_s$  dem thermischen Widerstand zur Kühlung. Die beiden Zustände des thermischen Modells sind die Kerntemperatur  $T_c$  und die Oberflächentemperatur  $T_s$ .

Basierend auf dem vorgestellten Modell lauten die bestimmenden Differentialgleichungen der  $n_{\text{cell}}$  Zellen

$$\dot{\mathbf{T}}_c(t) = \underbrace{\tau_c^{-1} \circ (\mathbf{T}_s(t) - \mathbf{T}_c(t)) + \mathbf{C}_c^{-1} \circ \mathbf{P}_{\text{cell}}(t)}_{f_c[t, \mathbf{T}_c(t)]} \quad (3.84)$$

für die Kerntemperatur und

$$\dot{\mathbf{T}}_s(t) = \underbrace{\tau_s^{-1} \circ (T_{\text{amb}}(t) \mathbf{1}_{n_{\text{cell}}} - \mathbf{T}_s(t)) - \tau_{cs}^{-1} \circ (\mathbf{T}_s(t) - \mathbf{T}_c(t)) + \mathbf{C}_s^{-1} \circ \mathbf{P}_{\text{ext}}(t)}_{f_s[t, \mathbf{T}_s(t)]} \quad (3.85)$$

für die Oberflächentemperatur, mit  $\tau_c = \mathbf{R}_c \circ \mathbf{C}_c$ ,  $\tau_s = \mathbf{R}_s \circ \mathbf{C}_s$  und  $\tau_{cs} = \mathbf{R}_c \circ \mathbf{C}_s$ . Die

Wärmekapazitäten  $\mathbf{C}_c$ ,  $\mathbf{C}_s$  und die thermischen Widerstände  $\mathbf{R}_c$ ,  $\mathbf{R}_s$  sind über die Zeit konstant, können aber innerhalb der Zellen untereinander variieren:

$$\mathbf{C}_c = \Delta_{C_c}(\sigma_{C_c}) \cdot \overline{C}_c \quad (3.86)$$

$$\mathbf{C}_s = \Delta_{C_s}(\sigma_{C_s}) \cdot \overline{C}_s \quad (3.87)$$

$$\mathbf{R}_c = \Delta_{R_c}(\sigma_{R_c}) \cdot \overline{R}_c \quad (3.88)$$

$$\mathbf{R}_s = \Delta_{R_s}(\sigma_{R_s}) \cdot \overline{R}_s. \quad (3.89)$$

Die Transformation der Differentialgleichungen (3.84) und (3.85) für die Kern- und Oberflächentemperatur führt zu den zeitdiskreten Gleichungen

$$f_c[k, \mathbf{T}_c[k]] = \tau_c^{\circ-1} \circ (\mathbf{T}_s[k] - \mathbf{T}_c[k]) + \mathbf{C}_c^{\circ-1} \circ \mathbf{P}_{\text{cell}}[k] \quad (3.90)$$

$$\begin{aligned} f_s[k, \mathbf{T}_s[k]] &= \tau_s^{\circ-1} \circ (\mathbf{T}_{\text{amb}}[k] - \mathbf{T}_s[k]) \\ &\quad - \tau_{cs}^{\circ-1} \circ (\mathbf{T}_s[k] - \mathbf{T}_c[k]) + \mathbf{C}_s^{\circ-1} \circ \mathbf{P}_{\text{ext}}[k]. \end{aligned} \quad (3.91)$$

Das Lösen von (3.91) mit der Mittelpunktsregel führt zu

$$\mathbf{T}_c[k+1] = \mathbf{T}_c[k] + hf_c \left[ k + \frac{h}{2}, \mathbf{T}_c[k] + \frac{h}{2} f_c[k, \mathbf{T}_c[k]] \right] \quad (3.92)$$

$$\mathbf{T}_s[k+1] = \mathbf{T}_s[k] + hf_s \left[ k + \frac{h}{2}, \mathbf{T}_s[k] + \frac{h}{2} f_s[k, \mathbf{T}_s[k]] \right] \quad (3.93)$$

für die Kerntemperatur  $\mathbf{T}_c$  und die Oberflächentemperatur  $\mathbf{T}_s$  der einzelnen Zellen.

### 3.2.3 Alterungsmodell

Die Parameter des elektrothermischen Modells hängen nicht nur vom SOC und von der Temperatur ab, sondern auch vom SOH der Zellen, siehe (3.66), (3.69), (3.71) und (3.72). Ein ganzheitliches Batteriemodell berücksichtigt deshalb auch das Alterungsverhalten der Zellen [94]. Die Zellalterung setzt sich aus der kalendarischen und zyklischen Alterung zusammen. Als größte Einflussfaktoren auf die kalendarische Alterung diskutiert die Literatur die Lagertemperatur und den Lager-SOC [10]. Für die zyklische Alterung kommen weitere Einflussfaktoren hinzu. Dazu gehören die Ladeschlussspannung [7], die Stromrate im Betrieb und der Gesamtladungsdurchsatz [41, 259]. Die Batteriealterung kann aus verschiedenen Perspektiven und mit unterschiedlichen Detaillierungsgraden beschrieben werden. Barré, Deguilhem u. a. unterteilen die am häufigsten verwendeten Alterungsmodelle in fünf Kategorien [10]: Elektrochemische, ECM-basierte, leistungsbasierte, analytische und statistische Alterungsmodelle. Aufgrund des guten Kompromisses zwischen Genauigkeit, Vorhersagekraft und Berechnungskomplexität integriert diese Arbeit im Folgenden ein analytisches Alterungsmodell in das Framework [10]. Cordoba-Arenas, Onori u. a. stellen ein semi-empirisches

Alterungsmodell für Pouch-Zellen vor, das auf einer experimentellen Alterungskampagne basiert [41]. Die Studie zielt darauf ab, die Batteriealterung im PHEV-Betrieb abzuschätzen und vorherzusagen. Die nachfolgenden Modifikationen passen das Alterungsmodell für BEVs an, was eine Integration in das Matrix-Vektor-basierte Modell-Framework ermöglicht.

Cordoba-Arenas, Onori u. a. untersuchen anhand der folgenden äußeren Faktoren die Einflüsse auf die zyklische Alterung [41]:

- Laderate ( $\mathbf{CR}$ )
- Batterietemperatur ( $\mathbf{T}_c$ )
- Charge-Depleting-(CD)-Verhältnis (*Ratio*)
- Minimaler SOC ( $\text{SOC}_{\min}$ )

Die Laderate oder C-Rate  $\mathbf{CR} \in \mathbb{R}^{n_{\text{cell}}}$  ist der auf die initiale Batteriekapazität normierte Ladestrom:

$$\mathbf{CR}(t) = \mathbf{i}_{\text{cell}}(t) \circ \mathbf{Q}^{\circ-1}(0). \quad (3.94)$$

*Ratio* bezeichnet den Betriebsmodus des PHEVs. Der Faktor gibt an, zu welchem Grad sich das Fahrzeug während der Fahrt im CD-Modus befindet. Ein Faktor von *Ratio* = 1 entspricht einem rein elektrischen Betrieb, bei dem die Batterie entladen wird. Ein Faktor von *Ratio* = 0 entspricht einem reinen Hybridbetrieb, bei dem der SOC weitgehend konstant bleibt. Für ein BEV gilt  $\text{Ratio}(t) \equiv 1 \forall t$ .  $\text{SOC}_{\min}$  gibt den minimalen SOC an. Dieser würde bei einem BEV theoretisch 0% betragen. In der Realität werden BEVs jedoch nicht vollständig entladen, bevor sie wieder aufgeladen werden. Da mehr als 80% der BEVs wieder aufgeladen werden, bevor ein SOC unter 30% erreicht ist [81], nimmt das Modell einen durchschnittlichen  $\text{SOC}_{\min} = 30\%$  an. Der Gesamtladungsdurchsatz ist mit

$$\dot{\mathbf{q}}_{\Sigma}(t) = |\mathbf{i}_{\text{cell}}(t)| \quad (3.95)$$

gegeben, was im Rahmen des Modell-Frameworks zu einer zellindividuellen Schrittweite

$$\mathbf{h}_q = \mathbf{q}_{\Sigma}[k+1] - \mathbf{q}_{\Sigma}[k] = \frac{h}{2} (|\mathbf{i}_{\text{cell}}[k]| + |\mathbf{i}_{\text{cell}}[k+1]|) \quad (3.96)$$

für die zugrunde liegende Dynamik führt. Cordoba-Arenas, Onori u. a. definieren einen experimentellen Kapazitätsabnahmefaktor gemäß

$$a_Q(\text{SOC}_{\min}) = \alpha_Q + \beta_Q(\text{SOC}_{\min} - \text{SOC}_0)^a. \quad (3.97)$$

Tabelle 3.1 liefert die identifizierten Parameter der Autoren [41]. Die Kapazitätsabnahme berechnet sich nach

$$\mathbf{SOH}_Q(t) = \mathbf{1}_{n_{\text{cell}}} - a_Q(\text{SOC}_{\min}) \exp \left[ \frac{-E_{aQ}}{R_g} \mathbf{T}_c^{\circ-1}(t) \right] \circ \mathbf{q}_{\Sigma}^{\text{ob}}(t), \quad (3.98)$$

**Tabelle 3.1:** Parametrierung des Alterungsmodells [41].

Kapazitätsabnahme	Widerstandszunahme
$\alpha_Q = 5.57$	$\alpha_R = 3205.3$
$\beta_Q = 96.10$	$\beta_R = 1.3674 \times 10^7$
	$\gamma_R = 36.342$
$a = 3$	$c = 5.45$
$b = 0.48$	$d = 0.9179$
	$e = 1.8277$
$\text{SOC}_0 = 0.25$	$\text{SOC}_0 = 0.25$
$\text{CR}_0 = 5$	$\text{CR}_0 = 5$
$E_{aQ} = 22\,406 \text{ J mol}^{-1}$	$E_{aR} = 5100 \text{ J mol}^{-1}$
$R_g = 8.314 \text{ J K}^{-1} \text{ mol}^{-1}$	$R_g = 8.314 \text{ J K}^{-1} \text{ mol}^{-1}$

wobei die elementweise Exponentialfunktion gemäß

$$\exp[\mathbf{A}] = \sum_{\kappa=0}^{\infty} \frac{1}{\kappa!} \mathbf{A}^{\circ\kappa} \quad (3.99)$$

definiert ist. Mit

$$\dot{\text{SOH}}_Q(t) = \text{dSOH}_Q(t, \mathbf{q}_\Sigma(t)) \circ \text{d}\mathbf{q}_\Sigma(t) \circ \text{d}\mathbf{q}_\Sigma(t)/\text{d}t \quad (3.100)$$

ist die Dynamik der Kapazitätsabnahme durch

$$\dot{\text{SOH}}_Q(t) = \underbrace{-ba_Q(\text{SOC}_{\min}) \exp\left[\frac{-E_{aQ}}{R_g} \mathbf{T}_c^{\circ-1}(t)\right]}_{f_Q(t)} \circ \mathbf{q}_\Sigma^{\circ b-1}(t) \circ |\dot{\mathbf{i}}_{\text{cell}}(t)| \quad (3.101)$$

gegeben. Da die Dynamik des Alterungsmodell deutlich langsamer ist als die Dynamik des elektrischen und thermischen Modells, wird (3.101) mit dem Euler-Verfahren gelöst:

$$\text{SOH}_Q[k+1] = \text{SOH}_Q[k] + hf_Q[k]. \quad (3.102)$$

Neben einer SOC-Abhängigkeit ist der experimentelle Widerstandszunahme-Faktor

$$a_R(\text{SOC}_{\min}, \mathbf{CR}(t)) = \alpha_R \mathbf{1}_{n_{\text{cell}}} + \beta_R (\text{SOC}_{\min} - \text{SOC}_0)^c \mathbf{1}_{n_{\text{cell}}} + \gamma_R \exp[d(\text{CR}_0 \mathbf{1}_{n_{\text{cell}}} - \mathbf{CR}(t)) + e(\text{SOC}_{\min} - \text{SOC}_0) \mathbf{1}_{n_{\text{cell}}}] \quad (3.103)$$

auch von der zellindividuellen Laderate  $\mathbf{CR}$  abhängig. Der widerstandsbasierte SOH ist durch

$$\text{SOH}_R(t) = \mathbf{1}_{n_{\text{cell}}} + a_R(\text{SOC}_{\min}, \mathbf{CR}(t)) \circ \exp\left[\frac{-E_{aR}}{R_g} \mathbf{T}_c^{\circ-1}(t)\right] \circ \mathbf{q}_\Sigma(t) \quad (3.104)$$



gegeben [41]. Mit

$$\dot{\mathbf{SOH}}_R(t) = d\mathbf{SOH}_R(t, \mathbf{q}_\Sigma(t)) \odot d\mathbf{q}_\Sigma(t) \odot d\mathbf{q}_\Sigma(t)/dt \quad (3.105)$$

folgt die Dynamik der Widerstandszunahme:

$$\dot{\mathbf{SOH}}_R(t) = \underbrace{a_R(\text{SOC}_{\min}, \mathbf{CR}(t)) \circ \exp \left[ \frac{-E_{aR}}{R_g} \mathbf{T}_c^{\circ-1}(t) \right] \circ |\mathbf{i}_{\text{cell}}(t)|}_{f_R(t)}. \quad (3.106)$$

Das Lösen von (3.106) mit der Euler-Methode führt zu

$$\mathbf{SOH}_R[k+1] = \mathbf{SOH}_R[k] + hf_R[k]. \quad (3.107)$$

### 3.3 Modellierung des Batteriepacks

Das im vorherigen Abschnitt vorgestellte Modell ermöglicht eine Matrix-Vektor-basierte Einzelzellsimulation. In Anlehnung an die Zustandsraumdarstellung fasst die Schreibweise

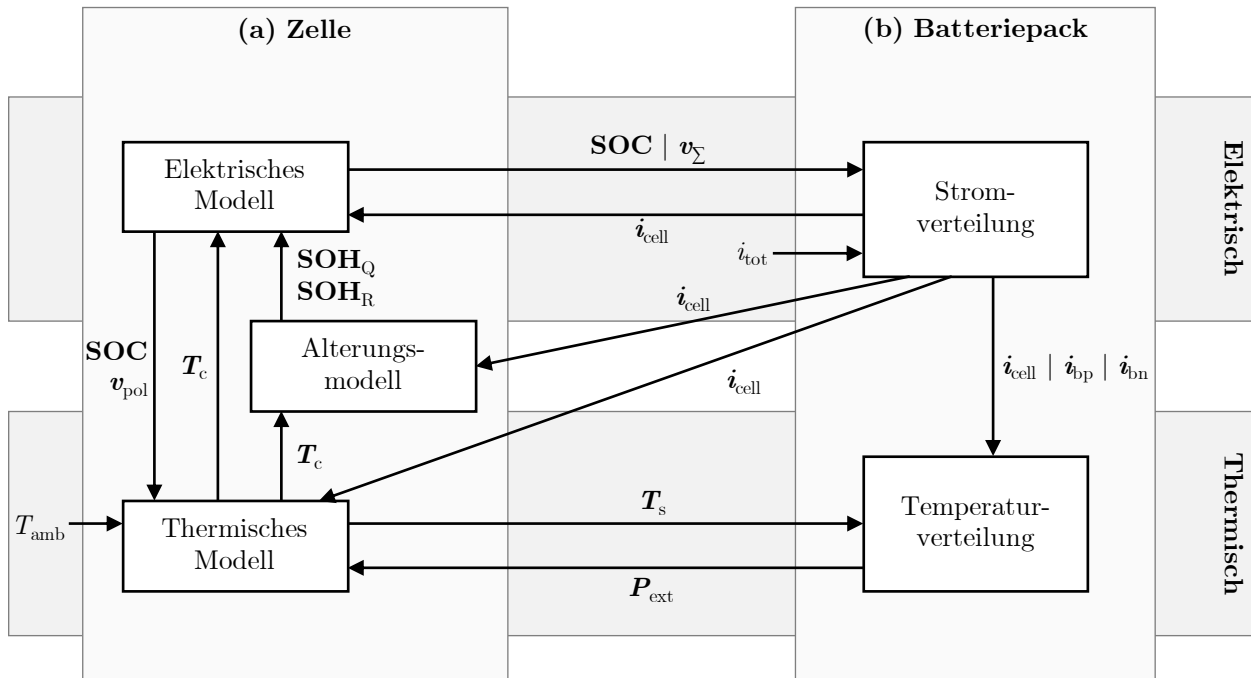
$$\begin{bmatrix} \dot{\mathbf{SOC}} & \dot{\mathbf{v}}_p \end{bmatrix} = \begin{bmatrix} \mathbf{0}_{n_{\text{cell}}} & -\boldsymbol{\tau}_p^{\circ-1} \end{bmatrix} \circ \begin{bmatrix} \mathbf{SOC} & \mathbf{v}_p \end{bmatrix} + \begin{bmatrix} \mathbf{Q}^{\circ-1} & \mathbf{C}_p^{\circ-1} \end{bmatrix} \circ \mathbf{i}_{\text{cell}} \mathbf{1}_{1+n_{\text{RC}}}^T \quad (3.108)$$

die Dynamik des elektrischen Modells zusammen. Mit dem Zustandsvektor  $[\mathbf{SOC} \ \mathbf{v}_p] \in \mathbb{R}^{n_{\text{cell}} \times (1+n_{\text{RC}})}$  bestehend aus dem SOC und den  $n_{\text{RC}}$  Polarisationsspannungen der  $n_{\text{cell}}$  Zellen. Die Eingänge des zeitvarianten Modells bilden die Anregungsströme  $\mathbf{i}_{\text{cell}}$ . Die Zeitvarianz kommt durch die vom Ladezustand  $\mathbf{SOC}$ , Alterungszustand  $\mathbf{SOH}_Q$ ,  $\mathbf{SOH}_R$  und von den Zellkerntemperaturen  $\mathbf{T}_c$  abhängigen Parameter zustande. Die Eingangs-Schnittstellen des elektrischen Modells bilden somit  $\mathbf{i}_{\text{cell}}$ ,  $\mathbf{SOH}_Q$ ,  $\mathbf{SOH}_R$  und  $\mathbf{T}_c$  (siehe Abbildung 3.3, Elektrisches Modell). Das thermische Modell lässt sich zu

$$\begin{aligned} \dot{\mathbf{T}}_c &= \boldsymbol{\tau}_c^{\circ-1} \circ (\mathbf{T}_s - \mathbf{T}_c) + \mathbf{C}_c^{\circ-1} \circ \mathbf{P}_{\text{cell}} \\ \dot{\mathbf{T}}_s &= \boldsymbol{\tau}_s^{\circ-1} \circ (T_{\text{amb}} \mathbf{1}_{n_{\text{cell}}} - \mathbf{T}_s) - \boldsymbol{\tau}_{cs}^{\circ-1} \circ (\mathbf{T}_s - \mathbf{T}_c) + \mathbf{C}_s^{\circ-1} \circ \mathbf{P}_{\text{ext}} \end{aligned} \quad (3.109)$$

zusammenfassen. Die Zustände  $[\mathbf{T}_c^T, \mathbf{T}_s^T]^T \in \mathbb{R}^{2n_{\text{cell}}}$  des thermischen Modells sind die Kerntemperaturen und Oberflächentemperaturen der Zellen. Die Eingänge bilden  $\mathbf{v}_{\text{pol}}$ ,  $\mathbf{SOC}$  und  $\mathbf{i}_{\text{cell}}$  zur Berechnung der Gesamtwärmegenerierung  $\mathbf{P}_{\text{cell}}$  der einzelnen Zellen nach (3.83). Weitere Eingänge sind der externe Wärmeaustausch  $\mathbf{P}_{\text{ext}}$  und die Umgebungstemperatur  $T_{\text{amb}}$  (siehe Abbildung 3.3, Thermisches Modell).

Ein wichtiger Teil eines ganzheitlichen Batteriepackmodells liegt in den Wechselwirkungen zwischen den Zellen, die dieser Abschnitt ergänzt (siehe Abbildung 3.3b). Parallel geschaltete Zellen tragen in Abhängigkeit von ihrer Impedanz, ihrem SOC und ihrer Polarisationsspannung



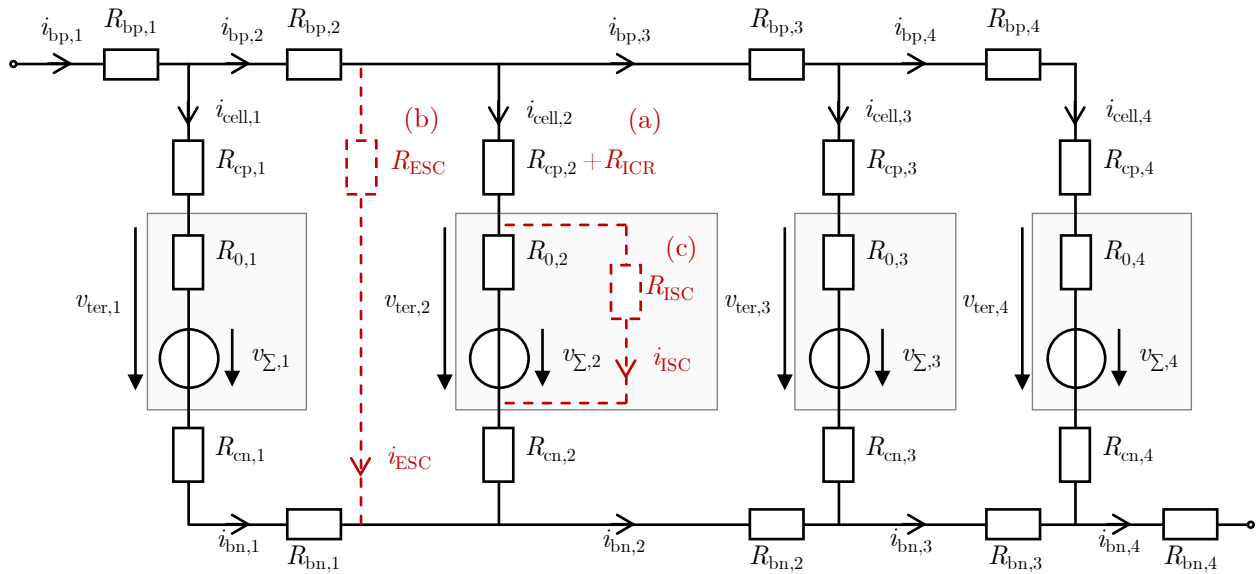
**Abbildung 3.3:** Übersicht des gesamten Modell-Frameworks, bestehend aus dem Zellmodell (a) mit dem elektrischen Modell, dem thermischen Modell und dem Alterungsmodell sowie dem Pack-Modell (b) mit dem Modell der Stromverteilung und der Temperaturverteilung.

unterschiedliche Anteile des Gesamtstroms (Abschnitt 3.3.1). Benachbarte Zellen zeigen thermische Wechselwirkungen, indem sie Temperaturunterschiede durch einen Wärmestrom ausgleichen (Abschnitt 3.3.2). Diese Effekte bilden die Eingänge  $i_{cell}$  und  $P_{ext}$  ab. Durch den Einbezug der Strom- und Temperaturverteilung findet auch die Alterung der einzelnen Zellen innerhalb des Batteriepacks Berücksichtigung. Zudem erfordert die Anwendung im Batteriesystem, die Parametervariationen (Abschnitt 3.3.3) zwischen den Zellen einzubeziehen.

### 3.3.1 Stromverteilung bei parallelen Zellen

Abbildung 3.4 zeigt ein Beispiel für eine typische Parallelschaltung von vier Batteriezellen in einem Batteriesystem. Zur Berechnung der Stromverteilung im Zeitschritt  $k$  lässt sich das N-RC-Modell ohne Genauigkeitsverlust zu einer Spannungsquelle mit Innenwiderstand vereinfachen. Nach (3.79) setzt sich die ideale Spannungsquelle  $v_{\Sigma}$  aus der OCV und den Polarisationsspannungen der RC-Glieder zusammen. Der Innenwiderstand  $R_0$  verursacht einen spontanen Ohmschen Spannungsabfall. Durch die Verschaltung der Batteriezellen treten im Allgemeinen zusätzliche Widerstände auf. Kontaktwiderstände  $R_{cp}$  und  $R_{cn}$  am Plus- und Minuspol treten seriell zu den Zellen auf. Zudem berücksichtigt das Modell die Stromschienenwiderstände  $R_{bp}$  und  $R_{bn}$ . Auf die rot markierten Fehler (a) - (c) gehen die Abschnitte 3.4 und 3.5 ein.

Nach den Kirchhoffschen Regeln gelten im elektrischen Netzwerk von Abbildung 3.4 die



**Abbildung 3.4:** Ersatzschaltbild der elektrischen Verschaltung von vier Zellen (grau). Die Fehlerfälle (a) erhöhter Kontaktwiderstand  $R_{ICR}$ , (b) externer Kurzschluss  $R_{ESC}$  und (c) interner Kurzschluss  $R_{ISC}$  sind rot markiert.

folgenden Gleichungen:

$$0 = i_{bp,1} - i_{tot} \quad (3.110a)$$

$$0 = v_{\Sigma,1} - v_{\Sigma,2} + R_{\Sigma,1}i_{cell,1} - R_{\Sigma,2}i_{cell,2} + R_{bn,1}i_{bn,1} - R_{bp,2}i_{bp,2} \quad (3.110b)$$

$$0 = v_{\Sigma,2} - v_{\Sigma,3} + R_{\Sigma,2}i_{cell,2} - R_{\Sigma,3}i_{cell,3} + R_{bn,2}i_{bn,2} - R_{bp,3}i_{bp,3} \quad (3.110c)$$

$$0 = v_{\Sigma,3} - v_{\Sigma,4} + R_{\Sigma,3}i_{cell,3} - R_{\Sigma,4}i_{cell,4} + R_{bn,3}i_{bn,3} - R_{bp,4}i_{bp,4} \quad (3.110d)$$

$$0 = i_{cell,1} - i_{bp,1} + i_{bp,2} \quad (3.110e)$$

$$0 = i_{cell,2} - i_{bp,2} + i_{bp,3} \quad (3.110f)$$

$$0 = i_{cell,3} - i_{bp,3} + i_{bp,4} \quad (3.110g)$$

$$0 = i_{cell,4} - i_{bp,4} \quad (3.110h)$$

$$0 = i_{cell,1} - i_{bn,1} \quad (3.110i)$$

$$0 = i_{cell,2} + i_{bn,1} - i_{bn,2} \quad (3.110j)$$

$$0 = i_{cell,3} + i_{bn,2} - i_{bn,3} \quad (3.110k)$$

$$0 = i_{cell,4} + i_{bn,3} - i_{bn,4}. \quad (3.110l)$$

Der Strom  $i_{bp,1}$  ist als Eingangsstrom  $i_{tot}$  definiert. Die in jedem Pfad in Reihe geschalteten Widerstände  $R_{cp}$ ,  $R_0$  und  $R_{cn}$  werden zum Widerstand  $R_{\Sigma} = R_{cp} + R_0 + R_{cn}$  zusammengefasst. Um das Beispiel aus Abbildung 3.4 auf das gesamte Batteriesystem mit  $n_{par}$  Zellen in Parallelschaltung und  $n_{ser}$  Zellen in Serienschaltung zu übertragen, erfolgt eine Definition der

folgenden Hilfsmatrizen:

$$\mathbf{E}_s = \begin{bmatrix} 0 & 0 \\ 0 & \mathbf{I}_{n_{\text{par}}-1} \end{bmatrix} = \begin{bmatrix} 0 & & & \\ & 1 & & \\ & & \ddots & \\ & & & 1 \end{bmatrix} \in \mathbb{R}^{n_{\text{par}} \times n_{\text{par}}} \quad (3.111)$$

und

$$\mathbf{F}_s = \begin{bmatrix} 0 & 0 \\ \mathbf{I}_{n_{\text{par}}-1} & 0 \end{bmatrix} = \begin{bmatrix} 0 & & & \\ 1 & \ddots & & \\ & \ddots & 0 & \\ & & & 1 & 0 \end{bmatrix} \in \mathbb{R}^{n_{\text{par}} \times n_{\text{par}}} \quad (3.112)$$

mit  $s \in [1, n_{\text{ser}}]$ . Das Modell nimmt an, dass jede serielle Gruppe  $s$  die gleiche Anzahl  $n_{\text{par}}$  parallel geschalteter Zellen hat, was in homogenen Batteriesystemen üblicherweise der Fall ist. Zudem erfolgt eine Definition der Blockdiagonalmatrizen

$$\mathbf{E} = \text{diag} \{ \mathbf{E}_1, \mathbf{E}_2, \dots, \mathbf{E}_{n_{\text{ser}}} \} = \begin{bmatrix} \mathbf{E}_1 & & & \\ & \mathbf{E}_2 & & \\ & & \ddots & \\ & & & \mathbf{E}_{n_{\text{ser}}} \end{bmatrix} \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{cell}}} \quad (3.113)$$

und

$$\mathbf{F} = \text{diag} \{ \mathbf{F}_1, \mathbf{F}_2, \dots, \mathbf{F}_{n_{\text{ser}}} \} = \begin{bmatrix} \mathbf{F}_1 & & & \\ & \mathbf{F}_2 & & \\ & & \ddots & \\ & & & \mathbf{F}_{n_{\text{ser}}} \end{bmatrix} \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{cell}}}. \quad (3.114)$$

Ausgehend von  $\mathbf{E}$  und  $\mathbf{F}$  werden die Matrix  $\mathbf{G} \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{cell}}}$ ,

$$\mathbf{G} = \mathbf{F} - \mathbf{E}, \quad (3.115)$$

und die Matrix  $\mathbf{H} \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{cell}}}$ ,

$$\mathbf{H} = \mathbf{F}^T - \mathbf{I}_{n_{\text{cell}}}, \quad (3.116)$$

definiert, wobei  $\mathbf{I}_n = \text{diag} \{ 1, \dots, 1 \} \in \mathbb{R}^{n \times n}$  die  $n \times n$ -dimensionale Einheitsmatrix ist. Mit dem Vektor  $\mathbf{m}_s = [1 \ 0 \ \dots \ 0]^T \in \mathbb{R}^{n_{\text{par}}}$  folgt die Matrix

$$\mathbf{M} = \text{diag} \{ \mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_{n_{\text{ser}}} \} = \begin{bmatrix} \mathbf{m}_1 & & & \\ & \mathbf{m}_2 & & \\ & & \ddots & \\ & & & \mathbf{m}_{n_{\text{ser}}} \end{bmatrix} \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{ser}}} \quad (3.117)$$

und der Vektor

$$\mathbf{m} = \begin{bmatrix} \mathbf{m}_1 \\ \mathbf{m}_2 \\ \vdots \\ \mathbf{m}_{n_{\text{ser}}} \end{bmatrix} \in \mathbb{R}^{n_{\text{cell}}}. \quad (3.118)$$

Die Diagonalmatrizen  $\mathbf{R}_{\text{cp}}, \mathbf{R}_{\text{cn}} \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{cell}}}$  und  $\mathbf{R}_{\text{bp}}, \mathbf{R}_{\text{bn}} \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{cell}}}$  der Kontakt- und Stromschienenwiderstände am Plus- und Minuspol berechnen sich gemäß

$$\mathbf{R}_{\text{cp}} = \mathbf{R}_{\text{cn}} = \text{diag}(\Delta_{\text{Rc}}(\sigma_{\text{Rc}})) \cdot \bar{R}_{\text{c}} \quad (3.119)$$

$$\mathbf{R}_{\text{bp}} = \mathbf{R}_{\text{bn}} = \text{diag}(\Delta_{\text{Rb}}(\sigma_{\text{Rb}})) \cdot \bar{R}_{\text{b}}, \quad (3.120)$$

mit dem mittleren Kontaktwiderstand  $\bar{R}_{\text{c}}$ , dem mittleren Stromschienen-Widerstand  $\bar{R}_{\text{b}}$  und den zugehörigen Standardabweichungen  $\sigma_{\text{Rc}}$  und  $\sigma_{\text{Rb}}$ , siehe (3.146). Der gemeinsame Serienwiderstand beträgt

$$\mathbf{R}_{\Sigma} = \text{diag}\{\mathbf{R}_0\} + \mathbf{R}_{\text{cp}} + \mathbf{R}_{\text{cn}} \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{cell}}}. \quad (3.121)$$

Wendet man das Kirchhoffsche Spannungsgesetz an und setzt  $i_{\text{tot}}$  als gegebenen Eingangsstrom, so resultiert

$$\mathbf{G}\mathbf{v}_{\Sigma} + \mathbf{G}\mathbf{R}_{\Sigma}\mathbf{i}_{\text{cell}} + \mathbf{F}\mathbf{R}_{\text{bn}}\mathbf{i}_{\text{bn}} - (\mathbf{E}\mathbf{R}_{\text{bp}} - \mathbf{M}\mathbf{M}^T)\mathbf{i}_{\text{bp}} = i_{\text{tot}}\mathbf{m} \quad (3.122)$$

für die Spannungen im elektrischen Stromkreis des Batteriesystems. Mit dem Kirchhoffschen Stromgesetz folgt

$$\mathbf{i}_{\text{cell}} + \mathbf{H}\mathbf{i}_{\text{bp}} = \mathbf{0} \quad (3.123)$$

$$\mathbf{i}_{\text{cell}} + \mathbf{H}^T\mathbf{i}_{\text{bn}} = \mathbf{0}. \quad (3.124)$$

Die Lösung von (3.123)-(3.124) für die Stromschienenströme  $\mathbf{i}_{\text{bp}}$  und  $\mathbf{i}_{\text{bn}}$  führt zu

$$\mathbf{i}_{\text{bp}} = \mathbf{H}^{-1}\mathbf{i}_{\text{cell}} \quad (3.125)$$


$$\mathbf{i}_{\text{bn}} = (\mathbf{H}^T)^{-1}\mathbf{i}_{\text{cell}}. \quad (3.126)$$

Die Gleichung (3.122) lässt sich mit den Stromschienenströmen  $\mathbf{i}_{\text{bp}}$  und  $\mathbf{i}_{\text{bn}}$  für die Zellströme

$$\mathbf{i}_{\text{cell}} = \mathbf{L}^{-1}(i_{\text{tot}}\mathbf{m} - \mathbf{G}\mathbf{v}_{\Sigma}) \quad (3.127)$$

lösen, wobei

$$\mathbf{L} = \mathbf{G}\mathbf{R}_{\Sigma} - \mathbf{F}\mathbf{R}_{\text{bn}}(\mathbf{H}^T)^{-1} + (\mathbf{E}\mathbf{R}_{\text{bp}} - \mathbf{M}\mathbf{M}^T)\mathbf{H}^{-1} \quad (3.128)$$



**Abbildung 3.5:** Elektrische Ersatzschaltbild darstellung des Temperaturverteilungsmodells für vier Zellen (grau) unter Berücksichtigung eines externen Wärmeeintrags  $P_{\text{ext},i}$  auf die Zelloberfläche.

ist. Für die Stromschienenströme folgt

$$\mathbf{i}_{\text{bp}} = \mathbf{H}^{-1} \mathbf{L}^{-1} (\mathbf{i}_{\text{tot}} \mathbf{m} - \mathbf{G} \mathbf{v}_{\Sigma}) \quad (3.129)$$

$$\mathbf{i}_{\text{bn}} = (\mathbf{H}^T)^{-1} \mathbf{L}^{-1} (\mathbf{i}_{\text{tot}} \mathbf{m} - \mathbf{G} \mathbf{v}_{\Sigma}). \quad (3.130)$$

### 3.3.2 Temperaturverteilung im Modul

Die einzelnen Zellen sind typischerweise mechanisch zu Modulen verbunden. Das Modell der Temperaturverteilung nimmt an, dass benachbarten Zellen innerhalb des Modulverbands thermische Wechselwirkungen aufweisen. Um den Wärmestrom  $P_{\text{ext}}$  zum Zeitschritt  $k$  zu bestimmen, erfolgt eine Vereinfachung des thermischen Modells aus Abbildung 3.2c ohne Genauigkeitsverlust zu einer thermischen Spannungsquelle (Abbildung 3.5). Das thermische Modell setzt sich aus der Oberflächentemperatur  $T_s$  der Zelle und einem thermischen Widerstand  $R_n$  zusammen, der den Wärmeübergang zwischen benachbarten Zellen basierend auf einer Temperaturdifferenz beschreibt. Die Oberfläche enthält eine zusätzliche Wärmequelle  $P_R$ . Diese resultiert aus den Ohmschen Verlusten, die sich aus den Kontaktwiderständen und den Widerständen der Stromschienen ergeben. Überträgt man die Kirchhoffschen Regeln von elektrischen Netzwerken auf das vorgestellte thermische Netzwerk, so gelten die folgenden Gleichungen:

$$0 = T_{s,2} - T_{s,1} + P_{n,1} R_{n,1} \quad (3.131a)$$

$$0 = T_{s,3} - T_{s,2} + P_{n,2} R_{n,2} \quad (3.131b)$$

$$0 = T_{s,4} - T_{s,3} + P_{n,3} R_{n,3} \quad (3.131c)$$

$$0 = P_{R,1} - P_{\text{ext},1} - P_{n,1} \quad (3.131d)$$

$$0 = P_{R,2} - P_{\text{ext},2} + P_{n,1} - P_{n,2} \quad (3.131e)$$

$$0 = P_{R,3} - P_{\text{ext},3} + P_{n,2} - P_{n,3} \quad (3.131f)$$

$$0 = P_{R,4} - P_{\text{ext},4} + P_{n,3}. \quad (3.131g)$$

Die zusätzliche Wärmequelle auf der Zelloberfläche berechnet sich gemäß

$$\mathbf{P}_R = (\mathbf{R}_{cp} + \mathbf{R}_{cn})\mathbf{i}_{cell}^{o2} + \frac{1}{2}\mathbf{U}\mathbf{R}_{bp}\mathbf{i}_{bp}^{o2} + \frac{1}{2}\mathbf{U}^T\mathbf{R}_{bn}\mathbf{i}_{bn}^{o2}, \quad (3.132)$$

mit der Hilfsmatrix

$$\mathbf{U} = \mathbf{I}_{n_{cell}} + \begin{bmatrix} 0 & \mathbf{I}_{n_{cell}-1} \\ 0 & 0 \end{bmatrix} = \begin{bmatrix} 1 & 1 & & \\ & 1 & \ddots & \\ & & \ddots & 1 \\ & & & 1 \end{bmatrix} \in \mathbb{R}^{n_{cell} \times n_{cell}}. \quad (3.133)$$

Um die Kirchhoffschen Regeln auf das thermische Netzwerk mit einer Anzahl von  $n_{cell}$  Zellen und  $n_{mod}$  Modulen mit  $n_{th} = n_{cell}/n_{mod}$  thermisch verbundenen Zellen in jedem Modul anzuwenden, werden die Hilfsmatrix

$$\mathbf{W}_m = \begin{bmatrix} -1 & 1 & & \\ & -1 & 1 & \\ & & \ddots & \ddots \\ & & & -1 & 1 \end{bmatrix} \in \mathbb{R}^{(n_{th}-1) \times n_{th}} \quad (3.134)$$

mit  $m \in [1, n_{mod}]$  und die Blockdiagonalmatrix

$$\mathbf{W} = \text{diag}\{\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_{n_{mod}}\} \in \mathbb{R}^{(n_{cell}-n_{mod}) \times n_{cell}} \quad (3.135)$$

definiert.  $\mathbf{R}_n$  berechnet sich gemäß

$$\mathbf{R}_n = \text{diag}\{\Delta_{R_n}(\sigma_{R_n})\} \cdot \overline{R}_n. \quad (3.136)$$

Die Anwendung des Kirchhoffschen Spannungsgesetzes

$$\mathbf{R}_n\mathbf{P}_n + \mathbf{W}\mathbf{T}_s = \mathbf{0} \quad (3.137)$$

und des Kirchhoffschen Stromgesetzes

$$-\mathbf{P}_{ext} + \mathbf{P}_R + \mathbf{W}^T\mathbf{P}_n = \mathbf{0} \quad (3.138)$$

liefert die Bestimmungsgleichungen des thermischen Netzwerks. (3.137) und (3.138) werden für die Wärmeübertragungsrate zu den benachbarten Zellen

$$\mathbf{P}_n = -\mathbf{R}_n^{-1}\mathbf{W}\mathbf{T}_s \quad (3.139)$$

und für die Wärmeübertragungsrate jeder Einzelzelle

$$\mathbf{P}_{\text{ext}} = \mathbf{P}_{\text{R}} - \mathbf{W}^T \left( \mathbf{R}_{\text{n}}^{-1} \mathbf{W} \mathbf{T}_{\text{s}} \right) \quad (3.140)$$

gelöst, um die Schnittstelle des Modell-Frameworks zu bedienen.

### 3.3.3 Parametervariation

Batteriesysteme weisen bereits im Ausgangszustand Parametervariationen auf [252]. Insbesondere Variationen der Impedanz, der Kapazität, des Coulombschen Wirkungsgrads und der Selbstentladerate beeinflussen die Konsistenz des Batteriepacks [328, 329]. Für parallel geschaltete Zellen ergibt sich daraus eine ungleiche Stromaufteilung [12], was zu zusätzlichen Ausgleichsströmen und einer inhomogenen Temperaturverteilung führt [77, 308].

Die Parametervariationen für eine Anzahl von  $n_{\text{cell}}$  Einzelzellen berücksichtigt das Modell durch einen Vektor mit Skalierungsfaktoren  $\Delta_{\text{X}} = [\delta_i]^T \in \mathbb{R}^{n_{\text{cell}}}$ ,  $i = 1 \dots n_{\text{cell}}$  für jeden Parameter  $X$ . Falls jede Zelle initial charakterisiert ist, existiert für jede Zelle ein individueller Skalierungsfaktor. Erfolgt keine zellindividuelle Charakterisierung, so werden die Parameter als normalverteilt angenommen [22]. Wenn ein Parameter  $X$  innerhalb eines  $q$  Prozent-Konfidenzintervalls weniger als  $x_{\text{var}}$  Prozent in seinem Wert schwankt, ist die Standardabweichung durch

$$\sigma_{\text{X}} = \frac{x_{\text{var}}}{\sqrt{2} \operatorname{erf}^{-1}(q)} \quad (3.141)$$

gegeben, wobei  $\operatorname{erf}^{-1}$  die inverse Fehlerfunktion

$$\operatorname{erf}(x) = \frac{1}{\sqrt{\pi}} \int_{-x}^x e^{-\xi^2} d\xi \quad (3.142)$$

ist. Ein Vektor  $\mathbf{x}_{\text{X}} \in \mathbb{R}^{n_{\text{cell}}}$  normalverteilter Zufallszahlen mit Mittelwert Null wird der Normalverteilung

$$\mathbf{x}_{\text{X}}(\sigma_{\text{X}}) \sim \mathcal{N}(\mathbf{0}_{n_{\text{cell}}}, \Sigma_{\text{X}}) \quad (3.143)$$

entnommen, wobei  $\Sigma_{\text{X}} = \operatorname{diag} \{ \sigma_{\text{X}} \} \in \mathbb{R}^{n_{\text{cell}} \times n_{\text{cell}}}$ . Ausgehend von dem Vektor  $\mathbf{x}_{\text{X}}$  lässt sich die Parametervariation durch einen Faktor

$$\Delta_{\text{X}}(\sigma_{\text{X}}) = \mathbf{1}_{n_{\text{cell}}} + \mathbf{x}_{\text{X}}(\sigma_{\text{X}}) \quad (3.144)$$

modellieren. Der resultierende Vektor

$$\Delta_{\text{X}}(\sigma_{\text{X}}) = \left[ \delta_1(\sigma_{\text{X}}) \quad \delta_2(\sigma_{\text{X}}) \quad \dots \quad \delta_{n_{\text{cell}}}(\sigma_{\text{X}}) \right]^T \in \mathbb{R}^{n_{\text{cell}}} \quad (3.145)$$

enthält die Verstärkungsfaktoren  $\delta_i(\sigma_{\text{X}})$  für jede Zelle  $i \in [1, n_{\text{cell}}]$  bezüglich des Parameters  $X$ . Die Wertetabelle  $\mathcal{X}: \mathbb{R}^{n_{\text{arg}}} \rightarrow \mathbb{R}$  mit einer Anzahl von  $n_{\text{arg}} \in \{1, 2\}$  Argumenten liefert



die SOC- und temperaturabhängigen Parameter  $x_i$  für jede Zelle  $i$ ,

$$\mathbf{X} = \Delta_{\mathbf{X}}(\sigma_{\mathbf{X}}) \circ \mathcal{X}[\mathbf{SOC}, \mathbf{T}] \in \mathbb{R}^{n_{\text{cell}}}. \quad (3.146)$$

### 3.4 Experimentelle Validierung

Zur Messung der zellenindividuellen Spannungen, Ströme und Temperaturen werden die sechs SMG-Zellen auf jeweils eine Platine gelötet, deren Sensoren die Größen  $v_{\text{ter},j}$ ,  $i_{\text{cell},j}$  und  $T_{s,j}$ ,  $j \in [1, 6]$  messen. Die Leiterplatten sind zu einem Modul in 2s3p-Konfiguration zusammengeschaltet. Jede Platine verfügt über einen 1 m $\Omega$ -Shunt-Widerstand zur Strommessung. Ein PT100-Temperatursensor misst die Temperatur. Da die SMG-Zellen auf jeweils eine Leiterplatte gelötet sind, berühren sich die Zellengehäuse nicht. Die Stromanregung erfolgt mit dem regenerativen Lade-/Entladetester Chroma 69225-60-4. Der Datenlogger HIOKI Memory Hilogger 8423 erfasst die Sensordaten mit einer Rate von 100 Hz. Die Spannungsauflösung beträgt 0.5 mV, die Stromauflösung 10 mA und die Temperatureauflösung 0.01 K. Die Tests erfolgen in einer BINDER-Temperaturkammer. Das Modell-Framework ist in MATLAB R2020b implementiert.

Die elektrothermische Charakterisierung der Zellen (siehe Abschnitte 2.2.2 und 2.2.3) erfolgt mit einem Arbin LBT 5 V/ 60 A Batterietester für drei PAN-Zellen und vier SMG-Zellen. Die Zellcharakterisierung besteht aus fünf Tests: Ein Kapazitätstest zur Bestimmung der tatsächlichen Kapazität, eine schrittweise Entladung der Zelle zur Bestimmung der OCV, eine potentiometrische Entropiemessung, ein HPPC-Test zur Parametrierung des ECMs und ein dynamischer Entladungstest zur Validierung der optimierten Parameter. Das CCCV-Ladeverfahren ist für jeden Test einheitlich. Die CC-Phase erfolgt mit einer Ladestromrate von 1 C basierend auf der nominalen Zellkapazität bis zur Ladeschlussspannung. Die CV-Phase endet, sobald der Strom unter eine Rate von 0.1 C fällt. Die CCCV-Ladung erfolgt in einer BINDER-Temperaturkammer bei einer konstanten Temperatur von 25 °C. Die nachfolgenden Absätze beschreiben die durchgeführten Charakterisierungstests.

**Kapazitätstest** Der Tester lädt die Zellen mit dem CCCV-Ladeverfahren und entlädt sie anschließend im CC-Modus, jeweils mit einer Stromrate von 1 C. Die Menge der bis zur Entladeschlussspannung entnommenen Ladung definiert der Kapazitätstest als extrahierbare Ladungsmenge der Zellen. Die Temperatur beträgt während des Kapazitätstests konstant 25 °C.

**Schrittweiser OCV-Test** Der Batterietester entlädt die Zellen mit einer Rate von  $-0.1$  C für 6 min, gefolgt von einer Pause von 10 min. Der Mittelwert der letzten 10 gemessenen Spannungswerte vor dem nächsten Stromimpuls bildet die Grundlage für die Berechnung der OCV. Die schrittweise Aufladung erfolgt analog mit einer Rate von 0.1 C. Die OCV berechnet

sich aus dem Mittelwert der ermittelten Werte für das Entladen und Laden. Die Temperatur beträgt während des schrittweisen OCV-Tests konstant 25 °C.

**Potentiometrische Entropiemessung** Zur Bestimmung des entropischen Wärmekoeffizienten entlädt der Tester die vollgeladenen Zellen in 5 % SOC-Schritten mit einer Rate von 0.1 C. In jedem Schritt ruhen die Zellen 3 h bis sich die OCV einstellt. Dann verändert die Klimakammer in der folgenden Sequenz ihre Temperatur: 25 °C, 45 °C, 15 °C, 35 °C, 25 °C. Die Zellen temperieren bei jedem Temperaturschritt 3 h bevor eine Spannungsmessung erfolgt. Nach der Temperierung bildet der Durchschnitt der letzten 10 gemessenen Spannungswerte den OCV-Wert für die vorliegende Temperatur und den vorliegenden SOC.

**HPPC-Test** Für die Parametrierung der in Abschnitt 3.2.1 vorgestellten ECMs regt der Tester die Zellen mit Stromimpulsen an. Die Anregung erfolgt mit Pulsen mit einer Rate von  $\pm 0.2$  C,  $\pm 1.0$  C,  $\pm 2.4$  C und einer Pulsdauer von jeweils 20 s. Nach jedem Puls ruhen die Zellen für 20 min. Dieser Vorgang wiederholt sich für mehrere SOC-Stufen. Der Tester stellt jede SOC-Stufe mit einer Rate von 0.2 C ein. Nach Erreichen einer SOC-Stufe starten die Pulstests nach einer weiteren Pause von 3 h. Um die Temperaturabhängigkeit der Parameter zu ermitteln, wiederholt sich der HPPC-Test für die Temperaturen 15 °C, 25 °C, 35 °C und 45 °C.

**Dynamischer Entladungstest** Um Messdaten für die Validierung der optimierten Parameter zu erhalten, regt der Batterietester die Zellen mit einem dynamischen Entladeprofil an. Die auf einen SOC von 95 % geladenen Zellen werden in mehreren Tests auf folgende Temperaturen temperiert: 15 °C, 25 °C, 35 °C, 45 °C. Anschließend entlädt der Tester die Zellen jeweils mit einem dynamischen Stromprofil, basierend auf dem WLTP, auf einen SOC von 10 %.

Die Validierung des Modells untersucht neben einer regulären Verschaltung der Zellen drei Fehlerfälle. Die Fehler werden während der Anregung des Moduls mit einem WLTP-Stromprofil eingebracht. Die Emulation eines erhöhten Kontaktwiderstands (Increased-Contact-Resistance, ICR) erfolgt durch eine serielle Verschaltung eines 68 m $\Omega$ -Widerstands mit der Zelle (Abbildung 3.4a). Das Modell simuliert den ICR durch Addition von  $R_{ICR} = 68$  m $\Omega$  zum Kontaktwiderstand des Pluspols zum Zeitpunkt des Fehlereintritts. Ein externer Kurzschluss (External-Short-Circuit, ESC) wird durch Verbinden eines 3.3  $\Omega$ -Widerstands an die Stromschiene induziert (Abbildung 3.4b). Die Modellierung des ESCs erfolgt durch eine zusätzliche elektrische Verbindung im Stromverteilungsmodell. Der zusätzliche Pfad enthält keine Spannungsquelle, sondern nur einen Widerstand  $R_{ESC} = 3.3$   $\Omega$  in Höhe des ESCs. Ein ISC einer Zelle wird emuliert, indem die Zelle mit einem 3.3  $\Omega$  Widerstand kurzgeschlossen wird (Abbildung 3.4c). Um den ISC in das Modell-Framework einzubeziehen, erfolgt eine Verschachtelung des Stromverteilungsmodells. Innerhalb der fehlerhaften Zelle verteilt sich der

Strom zwischen der elektrischen Zelle und dem Kurzschlusspfad  $i_{\text{ISC}}$ , was zu einer zusätzlichen Wärmeentwicklung von  $P_{\text{ISC}} = R_{\text{ISC}} \cdot i_{\text{ISC}}^2$  führt.

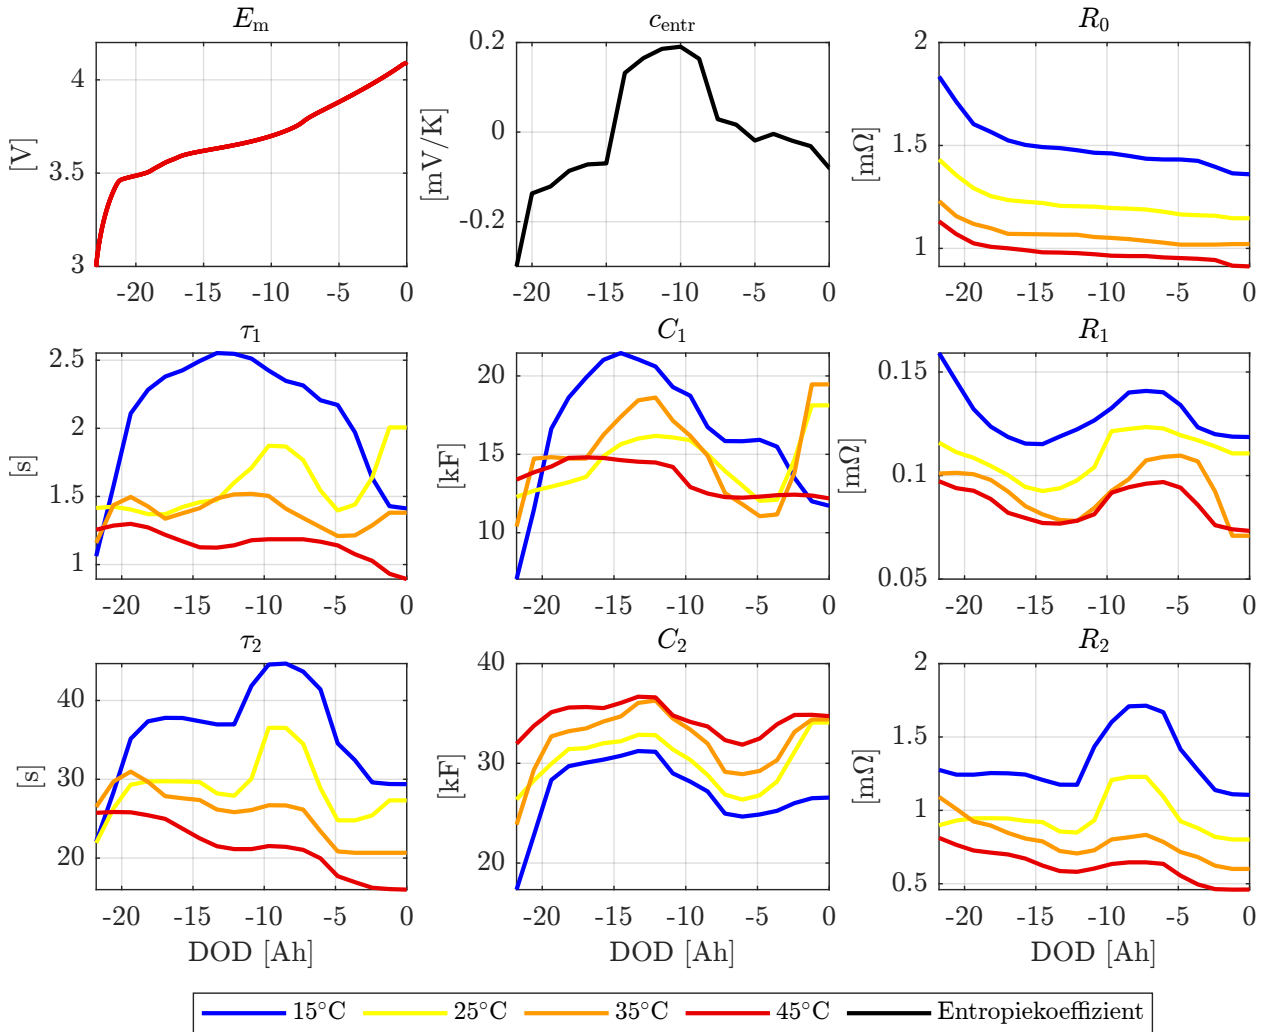
Soll die Balancing-Funktion von Batteriesystemen berücksichtigt werden, so kann beispielsweise der DOD nach einer vollständigen Ladung auf 0 Ah gesetzt werden, was einem *Top-Balancing* entspricht [223].

## 3.5 Ergebnisse und Diskussion

Die beschriebenen Tests identifizieren die Parameter des in Abschnitt 3.2-3.3 eingeführten Modell-Frameworks. Darüber hinaus parametrieren Werte aus der Literatur das Modell. Der Schwerpunkt der Validierung liegt auf der Evaluation des Modell-Frameworks und der optimierten Parameter (Abschnitt 3.5.1-3.5.2). Die Analyse des Modells liefert Ergebnisse für die Fehlerdiagnose in Batteriesystemen (Abschnitt 3.5.3). Abschnitt 3.5.4 diskutiert die Echtzeitfähigkeit des Modells.

### 3.5.1 Parametrierung des Zellmodells

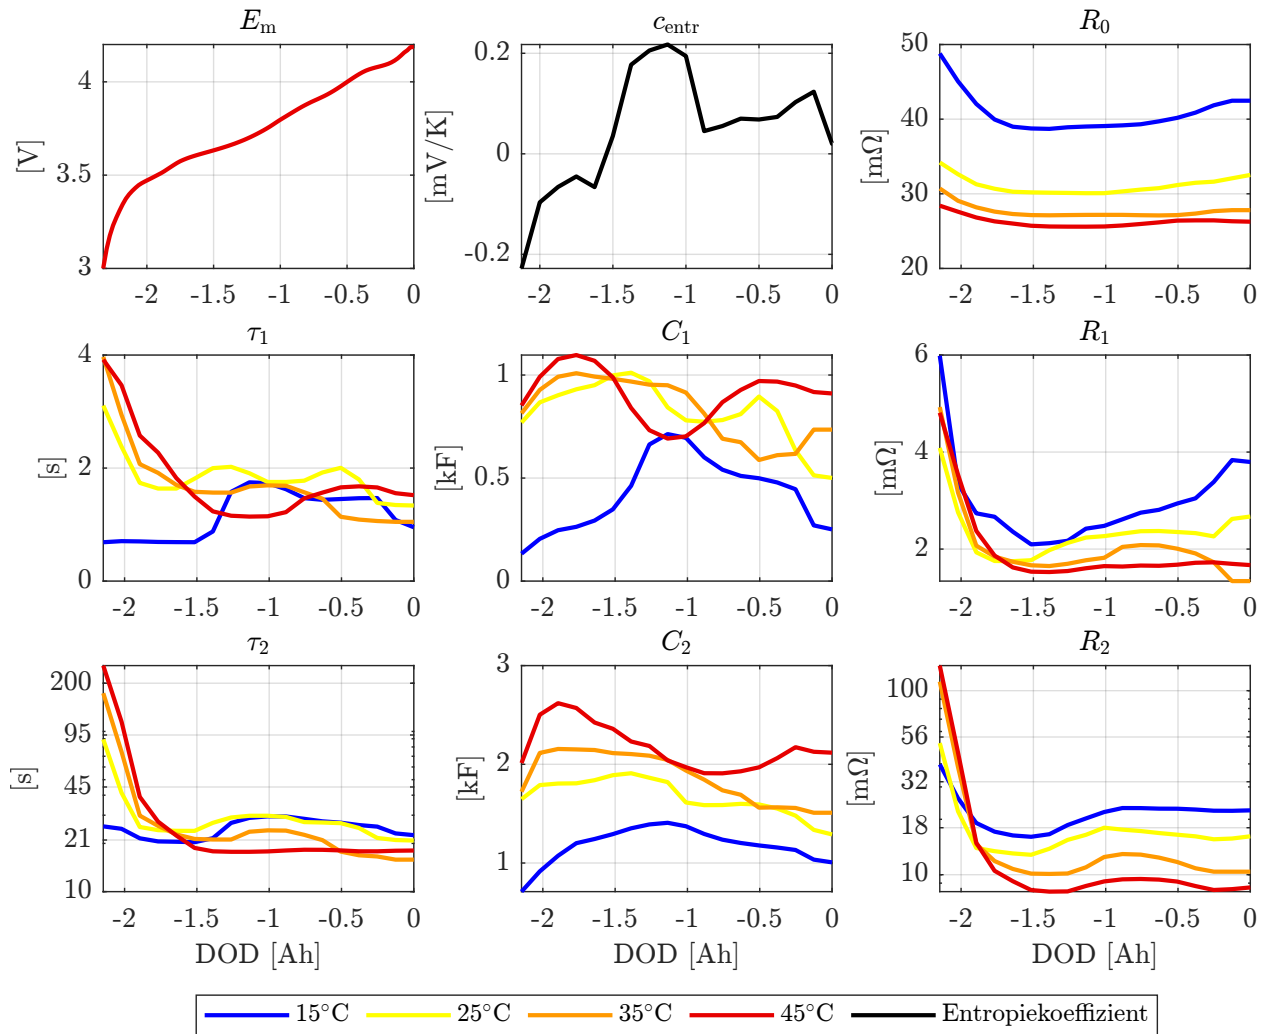
Basierend auf der Charakterisierung der drei PAN-Zellen beziehungsweise vier SMG-Zellen werden für jeden der beiden Zellentypen die Parameter eines gemeinsamen Modells identifiziert. Die Ergebnisse des Kapazitätstests zeigen eine durchschnittliche Kapazität von  $22.70 \text{ Ah} \pm 0.11 \text{ Ah}$  (PAN) und  $2.381 \text{ Ah} \pm 0.003 \text{ Ah}$  (SMG). Die PAN-Zellen weisen aufgrund ihres höheren kalendarischen Alters eine größere Kapazitätsschwankung auf als die SMG-Zellen. Der maximale Unterschied in der Kapazität innerhalb eines Zellentyps ist jedoch kleiner als 1%. Die für beide Zelltypen ermittelte OCV  $E_m$  ist in den Abbildungen 3.6 und 3.7 jeweils oben links dargestellt. Die Temperaturabhängigkeit der OCV ist an den ermittelten Entropiekoeffizienten  $c_{\text{entr}}$  erkennbar (Abbildungen 3.6 und 3.7, oben, Mitte). Das beobachtete Verhalten ist in guter Übereinstimmung mit früheren Studien [68, 231]. Unter Berücksichtigung des Entropiekoeffizienten  $c_{\text{entr}}$  zeigen beide Zellen eine positive Korrelation der OCV mit der Temperatur im mittleren SOC-Bereich und eine negative Korrelation der OCV mit der Temperatur im niedrigen und hohen SOC-Bereich. Die SOC- und temperaturabhängigen Parameter eines DP-Modells werden repräsentativ für das in Abschnitt 3.2.1 vorgestellte N-RC-Element-Thevenin-Modell identifiziert. Die Parameteridentifikation erfolgt in MATLAB durch einen hybriden Optimierungsansatz. Zunächst minimiert der globale Partikelschwarm-Optimierungsalgorithmus die Wurzel der mittleren Fehlerquadratsumme (Root-Mean-Square-Error, RMSE) zwischen der Spannungsreferenzmessung und dem Spannungsausgang des Modells. Dann minimiert eine Kombination von lokalen Liniensuchalgorithmen die Kostenfunktion weiter. Abbildungen 3.6 und 3.7 zeigen die resultierenden Parameter ( $R_0, \tau_1, C_1, R_1, \tau_2, C_2, R_2$ ) für beide Zelltypen mit ihrer SOC- und Temperaturabhängigkeit. Der Innenwiderstand und die Polarisationswiderstände beider Zellen steigen



**Abbildung 3.6:** Parameter eines DP-Modells für die PAN-Zelle mit ihren DOD- und Temperaturabhängigkeiten (15°C bis 45°C).

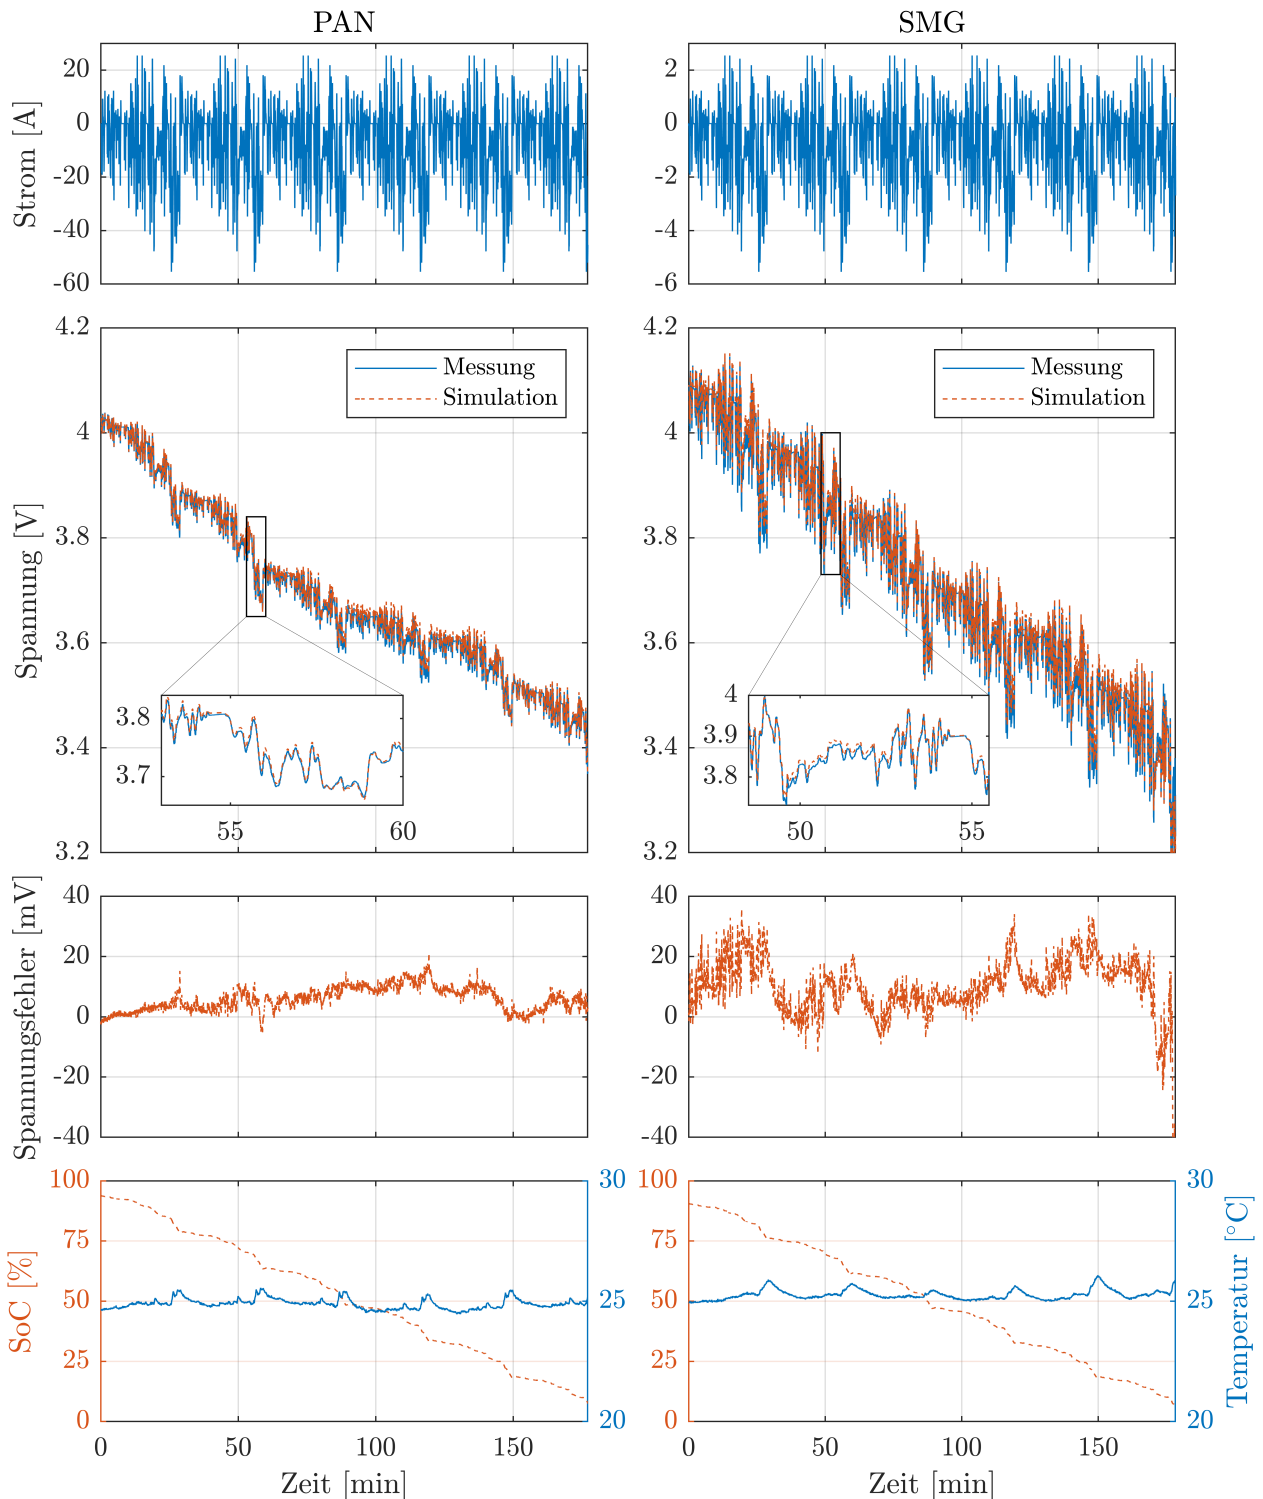
mit abnehmender Temperatur und geringerem DOD. In Übereinstimmung mit Samad, Siegel und Stefanopoulou sowie Skoog ist die Temperaturabhängigkeit der Widerstände dominanter als die Abhängigkeit vom SOC [231, 265]. Die Zeitkonstanten der RC-Glieder der PAN-Zellen nehmen mit abnehmender Temperatur zu, während die der SMG-Zellen stärker mit dem DOD korrelieren. Insbesondere der Widerstand  $R_2$  und die Zeitkonstante  $\tau_2$  der SMG-Zelle zeigen einen starken Anstieg bei niedrigeren SOC. Dies deutet auf nichtlineare Kapazitätseffekte, wie den Ratenkapazitätseffekt, hin, die das DP-Modell nicht abbildet [67].

Die Validierung aller Modelle erfolgt über den gesamten SOC-Bereich. Als Anregungsprofil dient das WLTP-basierte Stromprofil. Um die Parameter über den gesamten Temperaturbereich zu validieren, wiederholt sich das Verfahren für die Temperaturen 15°C, 25°C, 35°C und 45°C. Anstelle der Initialisierung durch (3.62) wird der initiale DOD der Zellen für die experimentellen Tests anhand der OCV-Kennlinie bestimmt. Stellvertretend für die anderen Temperaturen zeigt Abbildung 3.8 den Anregungsstrom, die gemessene und die simulierte



**Abbildung 3.7:** Parameter eines DP-Modells für die SMG-Zelle mit ihren DOD- und Temperaturabhängigkeiten (15°C bis 45°C).

Spannung sowie den Modellfehler und den SOC für beide Zelltypen bei 25°C. Während der Spannungsfehler für die PAN-Zelle eher systematisch ist (Abweichung von etwa 15 mV), ist der dynamische Fehler für die SMG-Zelle dominanter. Dies ist auf den höheren Innenwiderstand und die höheren Polarisationswiderstände zurückzuführen, wodurch der Fehler proportional ansteigt. Insgesamt ist der Fehler über den gesamten SOC-Bereich kleiner als 35 mV. Tabelle 3.2 listet den RMSE für alle Zellen bei allen Temperaturen auf. Dies zeigt, dass die Parameter auch über die verschiedenen Temperaturen hinweg gültig sind. Das thermische Modell und das Temperaturverteilungsmodell parametrieren die Literaturwerte aus Tabelle 3.3. Die Simulation verwendet die fettgedruckten Werte. Die Parameter der PAN-Zelle wurden an die Zellmasse und -abmessungen angepasst. Da sich die Gehäuse der SMG-Zellen nicht berühren, ist der Wärmewiderstand  $R_n$  für diesen Modulaufbau vernachlässigbar. Die Parameter des Alterungsmodells zeigt Tabelle 3.1 [41].



**Abbildung 3.8:** Validierung der identifizierten Zell-Parameter: Anregungsstrom, Vergleich von experimenteller und simulierter Spannung, Spannungsfehler, SOC-Bereich und Temperatur für beide Zellentypen PAN und SMG.

**Tabelle 3.2:** Resultierender RMSE der Zellspannungen für verschiedene Temperaturen. Die Zellen werden mit einem Profil basierend auf dem WLTP-Fahrzyklus von 100 % bis 10 % SOC entladen. Die fett markierten Werte entsprechen den in Abbildung 3.8 dargestellten Messungen und Simulationen.

Temperatur	PAN			SMG			
	Zelle 1	Zelle 2	Zelle 3	Zelle 1	Zelle 2	Zelle 3	Zelle 4
RMSE bei 15 °C [mV]	6.68	7.93	7.18	8.18	8.30	8.00	14.91
RMSE bei 25 °C [mV]	<b>6.97</b>	7.69	7.13	<b>10.29</b>	11.51	11.72	5.87
RMSE bei 35 °C [mV]	6.57	7.46	7.75	14.85	10.66	8.13	5.74
RMSE bei 45 °C [mV]	6.62	7.88	7.29	10.49	12.32	9.59	6.98

**Tabelle 3.3:** Parameter des thermischen Modells und des Temperaturverteilungsmodells. Die mit \* gekennzeichneten Werte wurden auf der Grundlage der Masse und der Abmessungen der PAN-Zelle berechnet. Die Simulation verwendet die fettgedruckten Werte.

	$\overline{R_c}$ [K W <sup>-1</sup> ]	$\overline{R_s}$ [K W <sup>-1</sup> ]	$\overline{C_c}$ [J K <sup>-1</sup> ]	$\overline{C_s}$ [J K <sup>-1</sup> ]	$\overline{R_n}$ [K W <sup>-1</sup> ]	Ref.
PAN	<b>1.773*</b>	<b>0.833*</b>	<b>556*</b>		<b>1.217*</b>	[49, 209] [33, 209] [74, 186]
SMG	1.83 3.2 – 3.4 <b>1.94</b>	3.03 8.4 – 9.1 <b>3.19</b>	67 73 – 78 <b>62.7</b>	4.5 <b>4.5</b>		[168] [79] [167]

**Tabelle 3.4:** Experimentell ermittelte Parametervariation der sechs zur Validierung verwendeten SMG-Zellen.

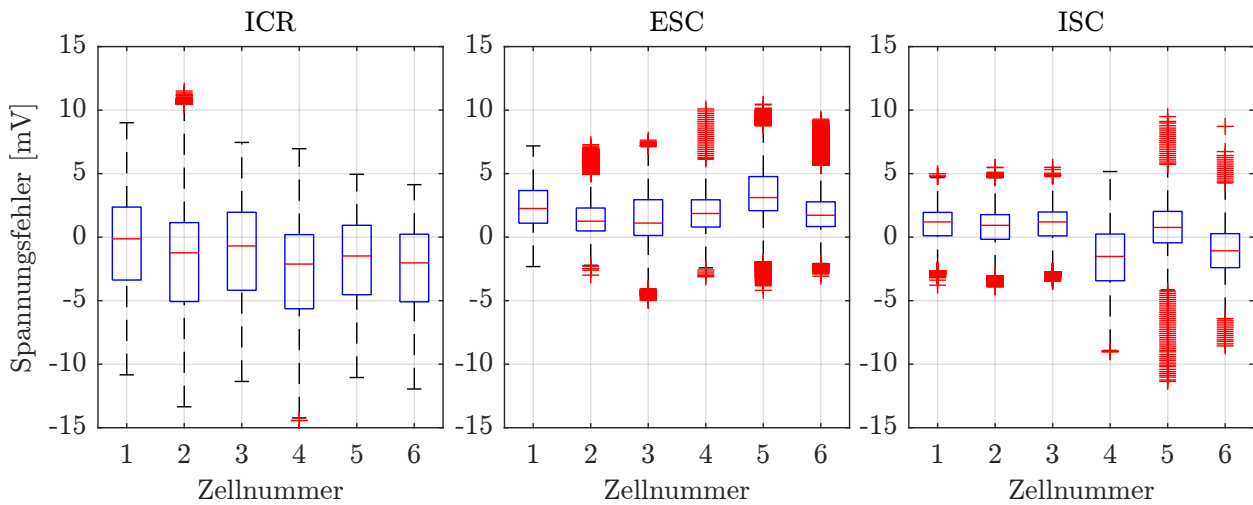
	Zelle (1,1)	Zelle (1,2)	Zelle (1,3)	Zelle (2,1)	Zelle (2,2)	Zelle (2,3)
$\Delta_Q$	0.9998	1.0011	1.0009	0.9990	1.0003	1.0023
$\Delta_{R_0}$	1.0390	0.8924	0.9929	0.9521	1.0075	1.0538
$\Delta_{C_1}$	0.9625	1.1205	1.0072	1.0503	0.9926	0.9490
$\Delta_{R_1}$	1.0390	0.8924	0.9929	0.9521	1.0075	1.0538
$\Delta_{C_2}$	0.9625	1.1205	1.0072	1.0503	0.9926	0.9490
$\Delta_{R_2}$	1.0390	0.8924	0.9929	0.9521	1.0075	1.0538

### 3.5.2 Parametrierung des Batteriepackmodells

Ein kurzer Check-up identifiziert die zellindividuellen Parameter der sechs Zellen des 2s3p-Moduls, sodass sie sich in Form von Skalierungsfaktoren  $\Delta_X$  in das Modell-Framework einbringen lassen. Tabelle 3.4 zeigt die für die Simulation verwendeten Faktoren. Die Parametrisierung der elektrischen Kontaktwiderstände erfolgt mit den Ergebnissen von Baumann,

**Tabelle 3.5:** Kontaktwiderstände für verschiedene Verbindungstechniken und deren Variation [12].

Verbindungstechnik	$R_c$ [m $\Omega$ ]	$x_{\text{var}}$	$q$
<b>Presskontakt</b>	<b>0.154 – 0.195<math>w</math></b>	<b>5.1 % – 6.5 %</b>	<b>90 %</b>
Widerstandspunktschweißen	0.167 – 0.196	10.2 % – 12.0 %	90 %
Ultraschallschweißen	0.169 – 0.318	18.9 % – 35.5 %	90 %
Laserstrahlschweißen	0.130 – 0.162	12.3 % – 15.4 %	90 %
Löten	0.080 – 0.111	18.0 % – 25.0 %	90 %

**Abbildung 3.9:** Box-Plot des Spannungsfehlers während der gesamten Simulation (WLTP) für jede Zelle und die drei Fehlerfälle ICR, ESC und ISC.

Wildfeuer u. a. [12]. Die Parameter zeigt Tabelle 3.5. Da die Zellen über einen Presskontakt mit den Stromschienen verbunden sind, werden die fett markierten Werte gewählt. Die Validierung des Modell-Framework erfolgt anhand der Messdaten der emulierten Fehler in Abschnitt 3.4. Ein Vergleich der Simulation mit den experimentellen Werten ist in den Abbildungen 3.10-3.12 für einen Zeitraum von jeweils 100 s dargestellt. Die Abbildungen zeigen jeweils die sechs Zellströme und Zellspannungen mit den entsprechenden Modellfehlern sowie die SOCs und die Temperaturfehler der sechs Zellen für die drei emulierten Fehlerfälle ICR, ESC und ISC. Eine gepunktete Linie zeigt den Zeitpunkt der Fehleremulation an. Aufgrund der geringen Ströme während der dynamischen Entladung (Betrag des Spitzenwerts  $< 1.5$  C) bleibt die Temperatur weitgehend konstant bei  $25^\circ\text{C} \pm 1^\circ\text{C}$ . Um das thermische Modell vollständig zu validieren, müssten die Zellen mit einem höheren Strom über einen längeren Zeitraum angeregt werden. Tabelle 3.6 zeigt die Modellfehler über den gesamten Messzeitraum von 1800 s bei einer dynamischen Entladung mit dem WLTP-basierten Stromprofil. Zudem ergänzt Abbildung 3.9 die Verteilung der Spannungsfehler während der gesamten Simulation. Die Modellfehler von weniger als 15 mV bei den drei Messungen bestätigen, dass das Simulationsmodell eine Einzelzellensimulation auch für Fehlerfälle ermöglicht. Die SOC-Differenz  $\Delta\text{SOC}$ , die Kapa-



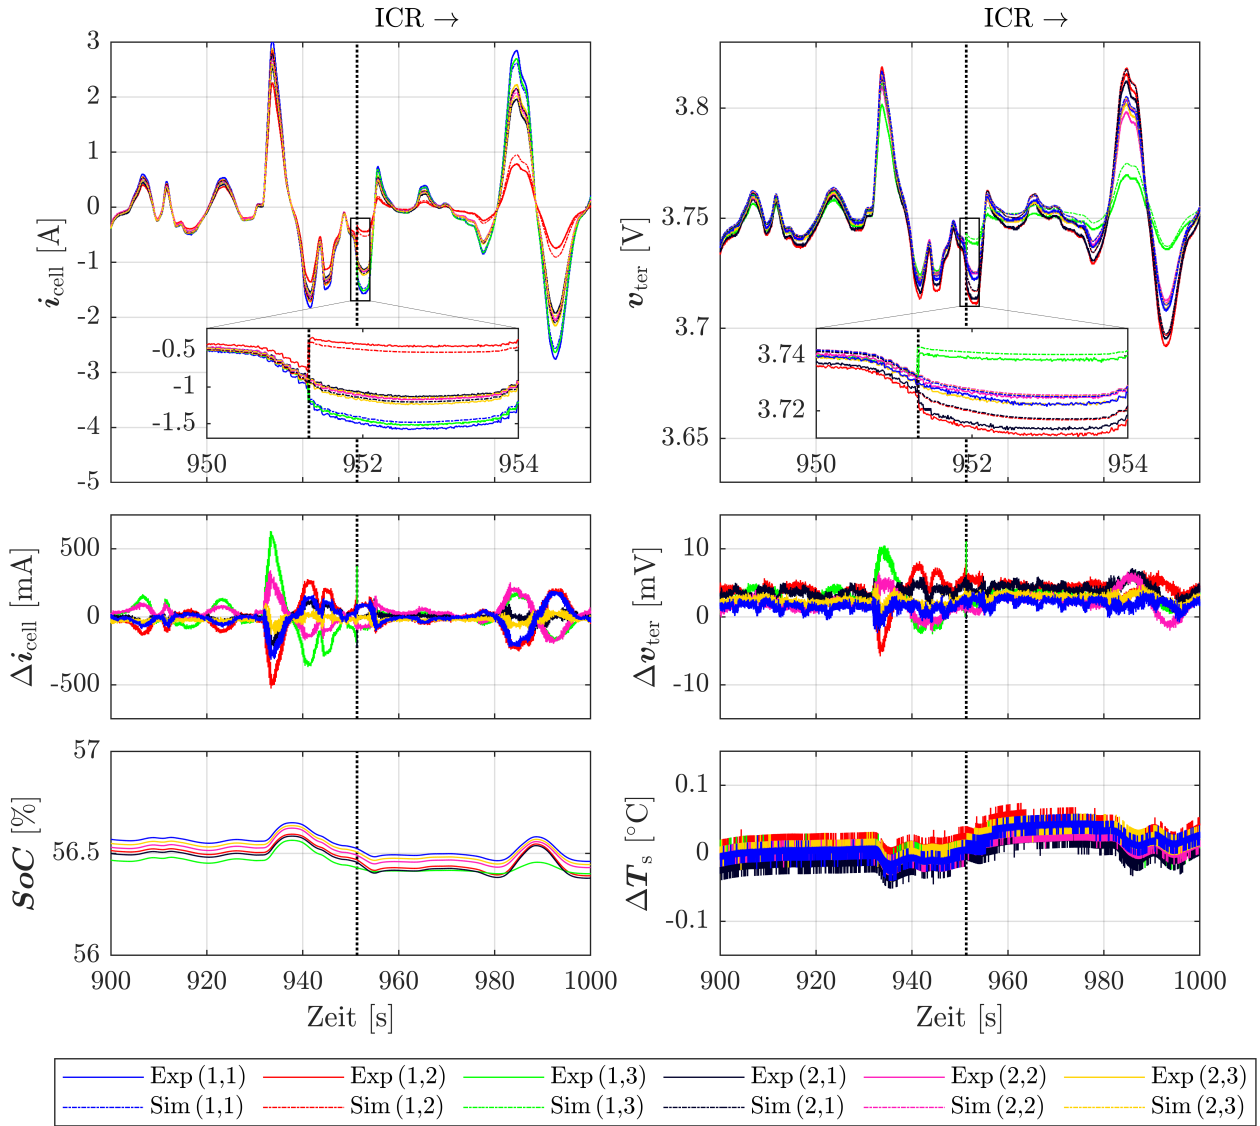
**Tabelle 3.6:** Simulationsergebnisse für die drei Fehlerfälle ICR, ESC und ISC: RMSE des Zellstroms, der Zellspannung und der Zelltemperatur sowie die SOC-Differenz  $\Delta\text{SOC} = \text{SOC}(1800s) - \text{SOC}(0s)$  und analog  $\text{SOH}_Q$ ,  $\text{SOH}_R$ .

		Zelle (1,1)	Zelle (1,2)	Zelle (1,3)	Zelle (2,1)	Zelle (2,2)	Zelle (2,3)
ICR	$i_{\text{cell}}$ -RMSE [mA]	95.01	111.40	32.95	67.60	22.09	68.39
	$v_{\text{cell}}$ -RMSE [mV]	3.94	4.86	4.26	5.09	4.24	4.44
	$T_{\text{cell}}$ -RMSE [°C]	0.09	0.11	0.07	0.08	0.08	0.06
	$\Delta\text{SOC}$ [ $\times 10^{-2}$ ]	-8.05	-5.90	-8.05	-7.31	-7.31	-7.38
	$\Delta\text{SOH}_Q$ [ $\times 10^{-4}$ ]	-10.04	-8.01	-10.04	-9.38	-9.38	-9.38
	$\Delta\text{SOH}_R$ [ $\times 10^{-5}$ ]	1.86	1.01	1.86	1.53	1.53	1.53
ESC	$i_{\text{cell}}$ -RMSE [mA]	60.56	84.25	42.66	76.13	62.35	27.33
	$v_{\text{cell}}$ -RMSE [mV]	2.90	2.01	2.40	2.76	4.00	2.50
	$T_{\text{cell}}$ -RMSE [°C]	0.27	0.25	0.23	0.19	0.21	0.16
	$\Delta\text{SOC}$ [ $\times 10^{-2}$ ]	-9.84	-9.85	-10.00	-7.27	-7.30	-7.42
	$\Delta\text{SOH}_Q$ [ $\times 10^{-4}$ ]	-9.82	-9.82	-9.86	-9.38	-9.38	-9.40
	$\Delta\text{SOH}_R$ [ $\times 10^{-5}$ ]	1.75	1.75	1.77	1.52	1.52	1.53
ISC	$i_{\text{cell}}$ -RMSE [mA]	38.35	41.03	17.71	75.23	98.26	40.00
	$v_{\text{cell}}$ -RMSE [mV]	1.57	1.52	1.63	2.91	2.44	2.39
	$T_{\text{cell}}$ -RMSE [°C]	0.14	0.15	0.15	0.15	0.20	0.35
	$\Delta\text{SOC}$ [ $\times 10^{-2}$ ]	-7.32	-7.34	-7.33	-9.63	-9.65	-10.20
	$\Delta\text{SOH}_Q$ [ $\times 10^{-4}$ ]	-9.39	-9.39	-9.39	-9.78	-9.78	-9.91
	$\Delta\text{SOH}_R$ [ $\times 10^{-5}$ ]	1.53	1.53	1.53	1.73	1.73	1.80

zitätsabnahme  $\Delta\text{SOH}_Q$  und die Widerstandserhöhung  $\Delta\text{SOH}_R$  sind ebenfalls in Tabelle 3.6 angegeben. Während die Änderung des SOC's etwa 6 % bis 10 % beträgt, sind die Änderungen von  $\text{SOH}_Q$  und  $\text{SOH}_R$  vernachlässigbar gering. Dies liegt daran, dass die Anregung mit dem WLTP-Stromprofil nur 1800s dauert und, abgesehen von kurzzeitigen Spitzen, geringe Stromstärken und wenig Erwärmung verursacht. Die Änderungen des SOHs geben jedoch einen Hinweis auf eine inhomogene Alterung bei Vorliegen von Fehlern im Batteriepack. Die Auswirkungen der Fehlerfälle auf  $\text{SOH}_Q$  und  $\text{SOH}_R$  erläutern die nachfolgenden Abschnitte für jeden Fehler separat.

### 3.5.3 Erkenntnisse für die Fehlerdiagnose

Der Schwerpunkt der Analyse der drei vorgestellten Fehlerfälle (Abbildung 3.10-3.12) liegt auf den Erkenntnissen zur Fehlerdiagnose, die aus der Detektion, Isolation und der Identifikation der Fehler besteht [17]. Aufgrund der Einzelzellsensoren ist eine Fehlerdiagnose durch Zellvergleich besonders vielversprechend.



**Abbildung 3.10:** Validierung des Modell-Frameworks am Fehlerfall ICR. Experimentelle (durchgezogene Linie) und simulierte (gestrichelte Linie) Größen der sechs Zellen im 2s3p-Modul: Zellströme, Stromfehler ( $\Delta i_{\text{cell}} = i_{\text{cell,sim}} - i_{\text{cell,exp}}$ ), Zellspannungen, Spannungsfehler ( $\Delta v_{\text{ter}} = v_{\text{ter,sim}} - v_{\text{ter,exp}}$ ), Ladezustand, Oberflächentemperaturfehler ( $\Delta T_s = T_{s,\text{sim}} - T_{s,\text{exp}}$ ).

### Erhöhter Kontaktwiderstand

In Abbildung 3.10 ist der ICR am positiven Pol von Zelle (1,2) etwa doppelt so groß wie der reguläre Gesamtwiderstand  $R_\Sigma$  der einzelnen Parallelpfade (siehe Abbildung 3.7,  $R_0$ ). Der Strom teilt sich invers zum Widerstand, was zu einer Aufteilung von

$$i_{\text{cell},1} : i_{\text{cell},2} : i_{\text{cell},3} = \frac{1}{R_\Sigma} : \frac{1}{3 \cdot R_\Sigma} : \frac{1}{R_\Sigma} \quad (3.147)$$

zwischen den parallel geschalteten Zellen führt. Die in Reihe geschalteten Zellen bleiben unbeeinflusst (Abbildung 3.10, „Exp (2,1-3)“). Da die Spannung jeder Zelle an ihren Anschlüssen gemessen wird, hat die Zelle im fehlerhaften Pfad aufgrund des geringeren Ohmschen

Spannungsabfalls und der niedrigeren Polarisationsspannung eine niedrigere Spannung (Abbildung 3.10,  $v_{\text{ter}}$ ). Wäre der Ohmsche Innenwiderstand der Zelle  $R_{0,2}$  erhöht, bliebe die Klemmenspannung weitgehend unverändert. Auf diese Weise ist ein ICR von einer Änderung des Zellinnenwiderstandes isolierbar. Die Größe des Fehlers lässt sich aus dem geänderten Teilungsverhältnis des Stroms abschätzen. Zum Zeitpunkt  $t_{\text{exp}} = 990\text{ s}$  (Abbildung 3.10, **SOC**) zeigt sich, dass die Zelle im fehlerhaften Parallelpfad, aufgrund der geringeren Entlade- und Ladeströme, geringere SOC-Änderungen im Vergleich zu den übrigen Zellen aufweist (Tabelle 3.6, ICR). Dementsprechend zeigen die Zelle (1,1) und Zelle (1,3) eine höhere Kapazitätsabnahme  $\Delta\text{SOH}_Q$  und eine höhere Widerstandserhöhung  $\Delta\text{SOH}_R$ . Dies ist auf die höheren Ströme und die damit einhergehenden höheren Temperaturen zurückzuführen (Tabelle 3.6, ICR).

### Externer Kurzschluss

Der ESC (Abbildung 3.11) an den Stromschienen verhält sich wie eine zusätzliche Last für alle parallel zum ESC verbundenen Zellen. Die in Reihe geschalteten Zellen bleiben unbeeinflusst (Abbildung 3.11, „Exp (2,1-3)“). Aufgrund der Stromschienenwiderstände tragen die an den ESC grenzenden Zellen einen etwas höheren Strom. Durch den Vergleich der Stromverteilung innerhalb der parallelen Zellen vor und nach dem ESC ist es möglich, den Fehler zu lokalisieren. An den Terminals der Zellen (Abbildung 3.11,  $v_{\text{ter}}$ ), die parallel zum ESC angeordnet sind, ist ein zusätzlicher Spannungsabfall durch die Ohmsche Last zu beobachten. Der ESC führt zu einer schnelleren Entladung der Zellen im entsprechenden Parallelstrang (Abbildung 3.11, **SOC**). Über die Simulationszeit von 1800 s summiert sich dieser Unterschied zu etwa 2.5 Prozentpunkten bezogen auf den SOC (Tabelle 3.6, ESC). Der größere Ladedurchsatz der Zellen (1,1-3) führt zu einer erhöhten Kapazitätsabnahme und Widerstandserhöhung im Vergleich zu den Zellen 2,1-3 (Tabelle 3.6, ESC).

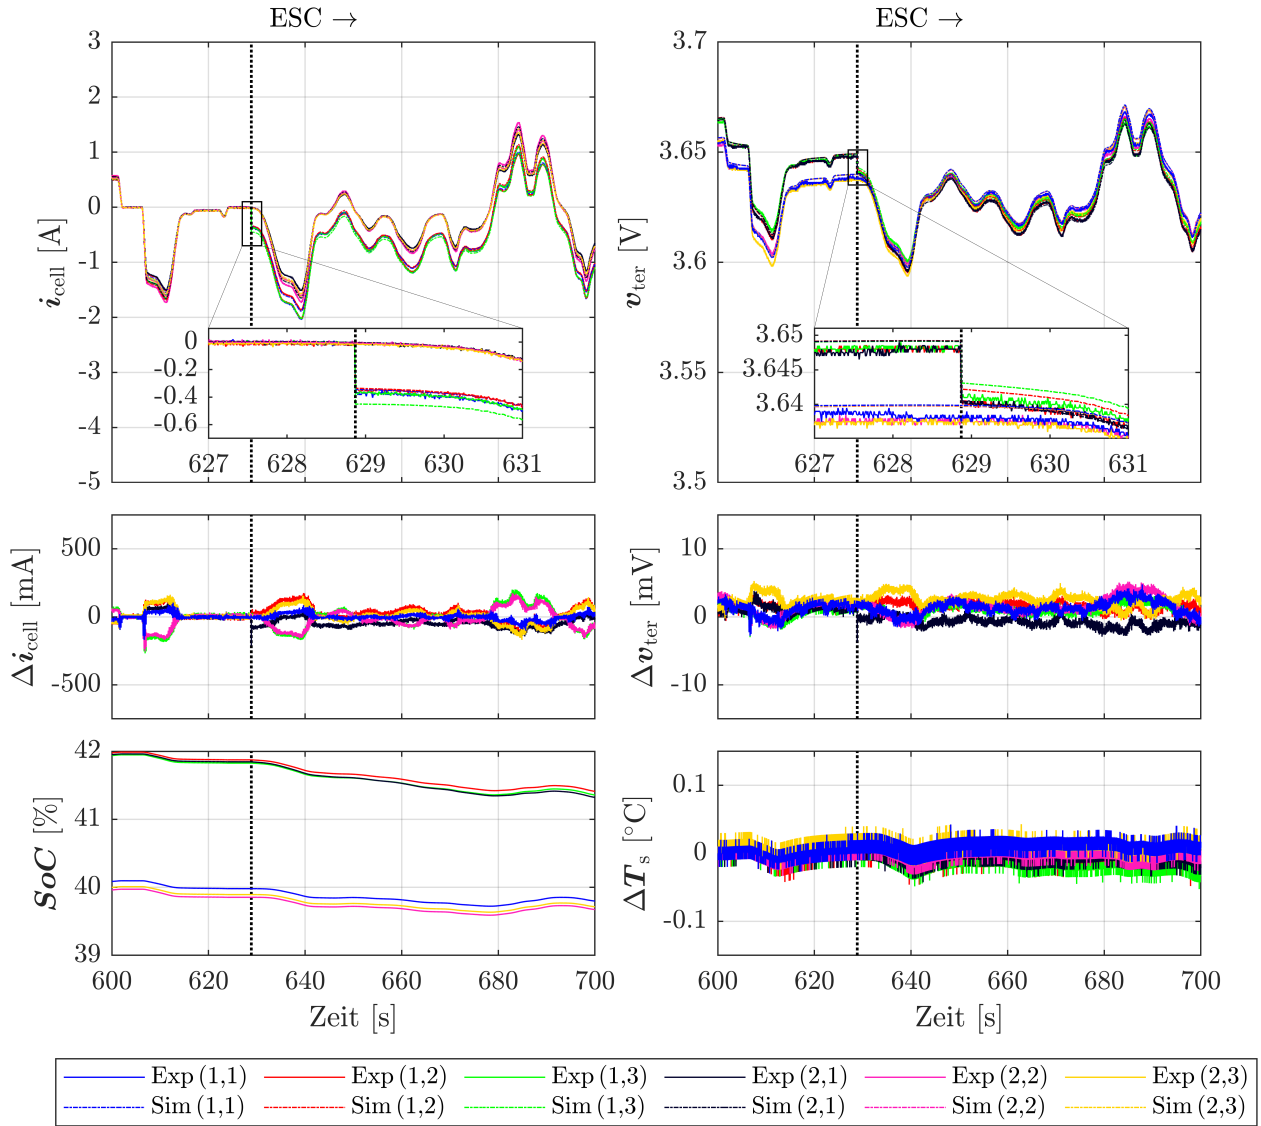
### Interner Kurzschluss

Während der ICR nur in Phasen mit externer Anregung beobachtet werden kann, führt der ISC an Zelle (2,3) zu einem zusätzlichen Ladestrom (Abbildung 3.12,  $i_{\text{cell}}$ ) der entsprechenden Zelle, der den ISC speist. Die fehlerhafte Zelle (Abbildung 3.12, „Exp (2,3)“) hat eine effektive Spannung von

$$V_{\Sigma,\text{ISC}} = \frac{R_{\text{ISC}}}{R_0 + R_{\text{ISC}}} \cdot V_{\Sigma} \quad (3.148)$$

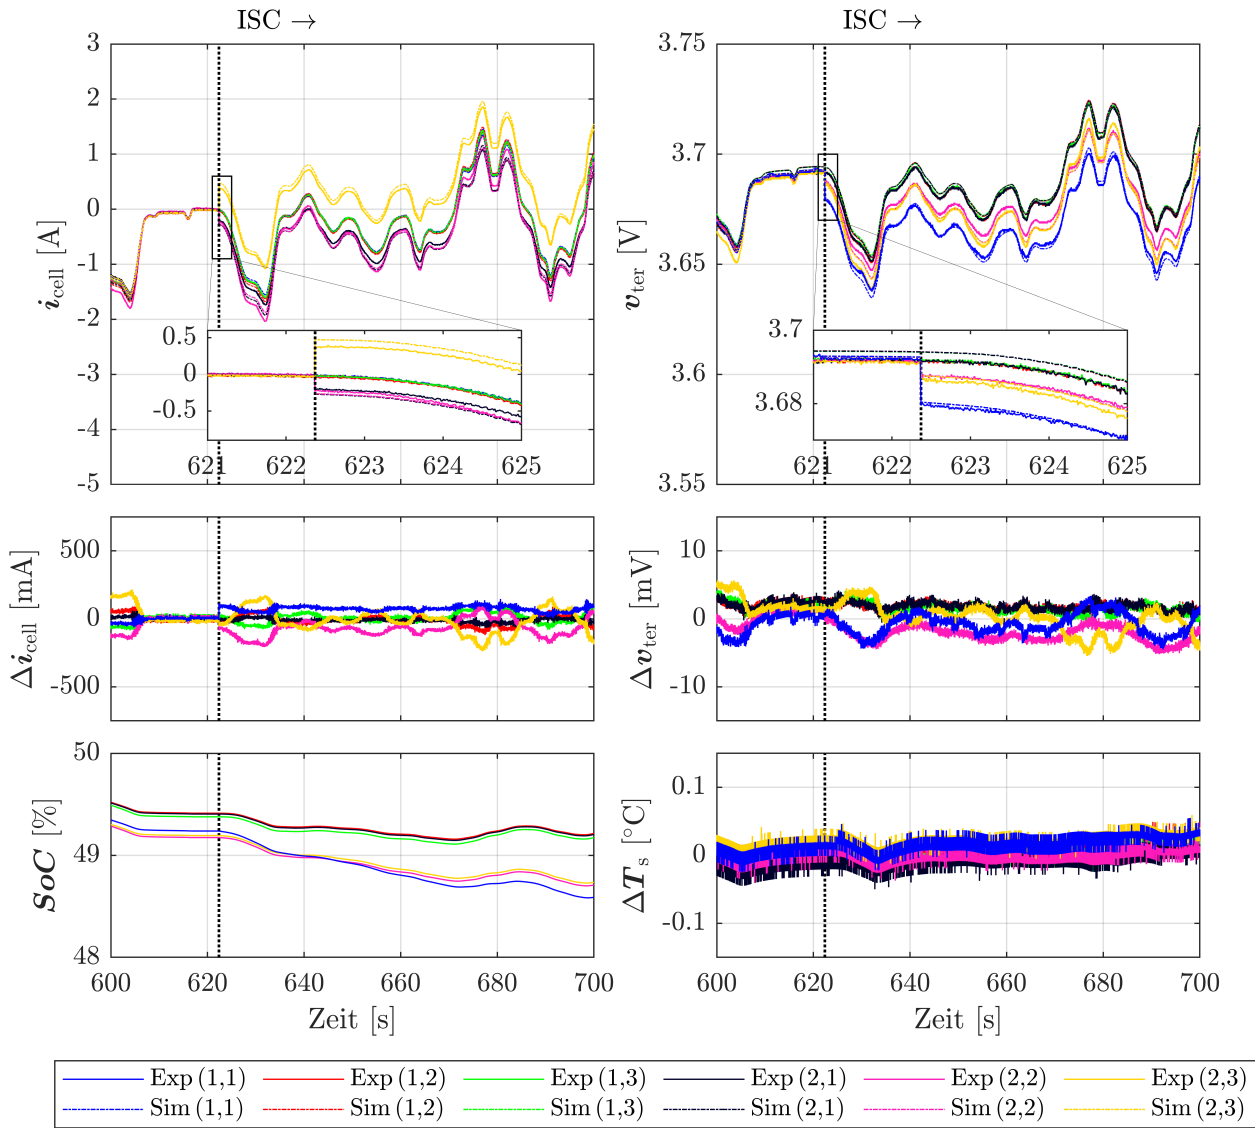
an den Klemmen und einen effektiven Innenwiderstand von

$$R_{0,\text{ISC}} = \frac{R_{\text{ISC}}}{R_0 + R_{\text{ISC}}} \cdot R_0 \quad (3.149)$$



**Abbildung 3.11:** Validierung des Modell-Frameworks am Fehlerfall ESC. Experimentelle (durchgezogene Linie) und simulierte (gestrichelte Linie) Größen der sechs Zellen im 2s3p-Modul: Zellströme, Stromfehler ( $\Delta i_{\text{cell}} = i_{\text{cell,sim}} - i_{\text{cell,exp}}$ ), Zellspannungen, Spannungsfehler ( $\Delta v_{\text{ter}} = v_{\text{ter,sim}} - v_{\text{ter,exp}}$ ), Ladezustand, Oberflächentemperaturfehler ( $\Delta T_s = T_{s,\text{sim}} - T_{s,\text{exp}}$ ).

(vergleiche Abschnitt 2.3.1). Die Parallelzellen speisen die fehlerhafte Zelle, da diese eine geringere effektive Klemmenspannung  $V_{\Sigma,\text{ISC}} < V_{\Sigma}$  im Vergleich zu den benachbarten Parallelzellen besitzt (Abbildung 3.12,  $v_{\text{ter}}$ ). Ihr reduzierter Widerstand  $R_{0,\text{ISC}} < R_0$  erhöht auch ihren Anteil am Gesamtstrom. Der SOC der fehlerhaften Zelle zeigt an, dass die Zelle sich selbst entlädt (Abbildung 3.12, **SOC**). Darüber hinaus führt die Speisung der parallel geschalteten Zellen 2,1-2 zu einer stärkeren Entladung der Zellen (2,1-3) im Vergleich zu den in Reihe geschalteten Zellen (1,1-3). Die erhöhte Entladerate der Zellen (2,1-3) führt zu einer stärkeren Abnahme des SOC's (Tabelle 3.6, ISC). Da der ISC nur elektrisch emuliert wird, ändert sich die experimentell ermittelte Temperatur der fehlerhaften Zelle nur geringfügig (Abbildung 3.12,  $T_s$ ). Ein tatsächlicher ISC würde jedoch zu dem im Modell berücksichtigten



**Abbildung 3.12:** Validierung des Modell-Frameworks am Fehlerfall ISC. Experimentelle (durchgezogene Linie) und simulierte (gestrichelte Linie) Größen der sechs Zellen im 2s3p-Modul: Zellströme, Stromfehler ( $\Delta i_{\text{cell}} = i_{\text{cell,sim}} - i_{\text{cell,exp}}$ ), Zellspannungen, Spannungsfehler ( $\Delta v_{\text{ter}} = v_{\text{ter,sim}} - v_{\text{ter,exp}}$ ), Ladezustand, Oberflächentemperaturfehler ( $\Delta T_s = T_{s,\text{sim}} - T_{s,\text{exp}}$ ).

zusätzlichen Wärmeeintrag von  $P_{\text{ISC}} = R_{\text{ISC}} i_{\text{ISC}}^2$  führen.

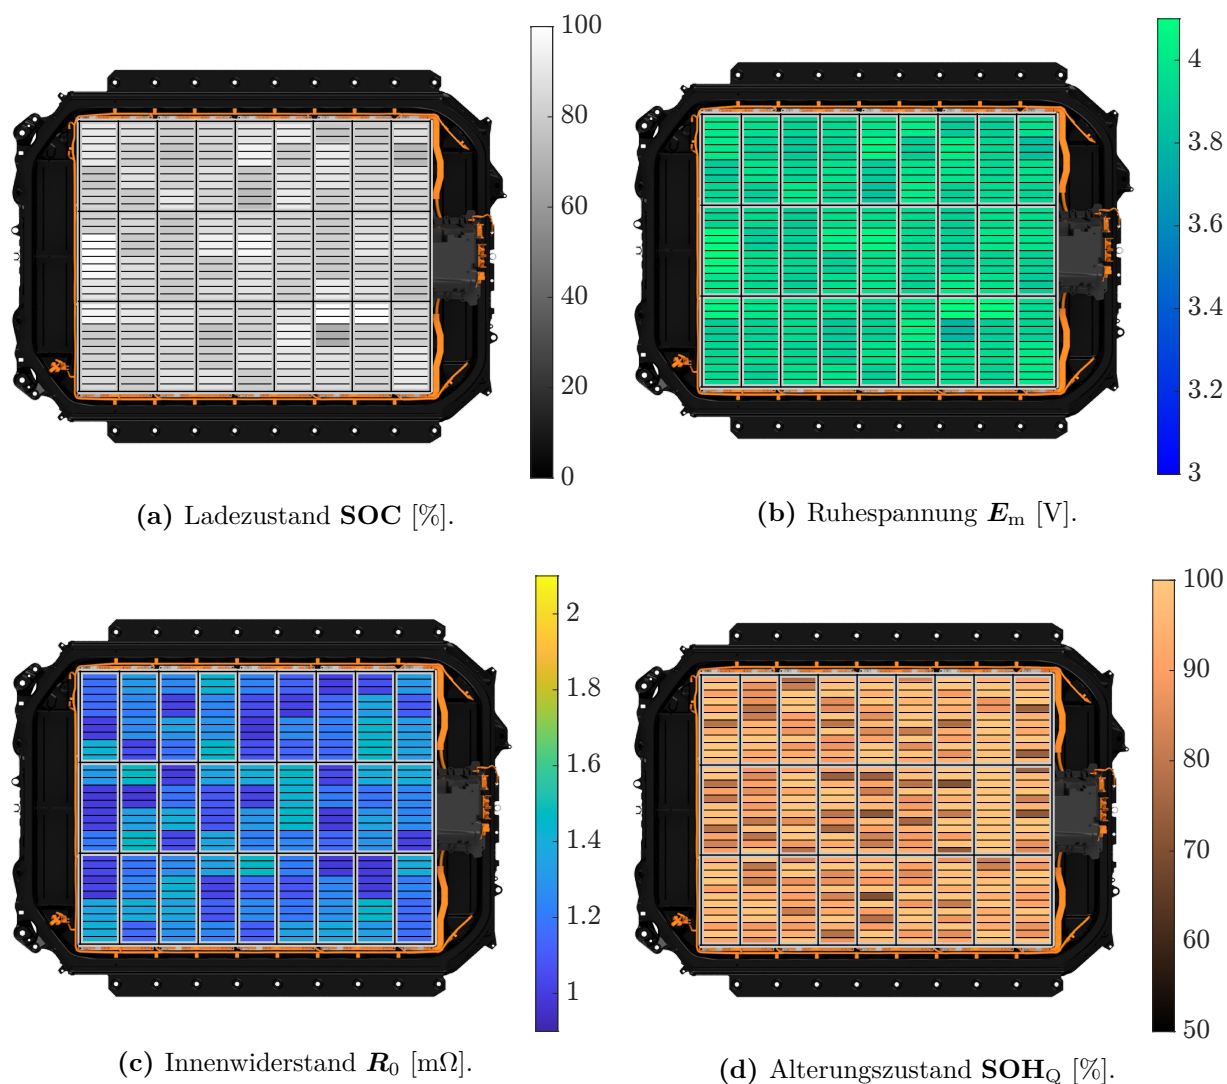
### 3.5.4 Simulationsdauer des Modell-Frameworks

Zur Bewertung der Simulationsdauer wird das Modell-Framework in MATLAB R2019a auf einer regulären Intel Core i7-7700HQ CPU (2.80 GHz) ohne Parallelisierung simuliert. Die Simulation erfolgt mit einem Batteriepack in 100s5p-Konfiguration, bestehend aus  $n_{\text{mod}} = 50$  Modulen. Die Grundlage des elektrischen Modells der  $n_{\text{cell}} = 500$  Zellen bildet das in Abschnitt 3.2.1 vorgestellte DP-Modell. Das Stromverteilungsmodell berechnet die Ströme der  $n_{\text{par}} = 5$  parallel und  $n_{\text{ser}} = 100$  seriell verschalteten Zellen. Die Zustandsvektoren besitzen

**Tabelle 3.7:** Simulationszeiten eines 100s5p-Batteriesystems mit 50 Modulen für 100 s mit unterschiedlichen Schrittweiten  $h$  (Schrittzahl  $N_h = 100\text{ s}/h$ ). Die Simulationszeiten werden für die einzelnen Modelle aufgeschlüsselt: Stromverteilung (SV), Temperaturverteilung (TV), Elektrisches Modell (EM), Alterungsmodell (AM), Thermisches Modell (TM).

$h$	$N_h$		Gesamt	SV	TV	EM	AM	TM	Rest
1 s	100	Dauer [s]	0.64	0.31	0.07	0.03	0.02	0.01	0.21
		Anteil [%]	100	49	10	4	3	1	33
0.1 s	1000	Dauer [s]	5.48	3.88	0.79	0.25	0.20	0.04	0.31
		Anteil [%]	100	71	14	5	4	1	6
<b>0.01 s</b>	10 000	<b>Dauer [s]</b>	<b>53.37</b>	<b>39.88</b>	<b>8.11</b>	<b>2.40</b>	<b>1.91</b>	<b>0.37</b>	<b>0.70</b>
		<b>Anteil [%]</b>	<b>100</b>	<b>75</b>	<b>15</b>	<b>4</b>	<b>4</b>	<b>1</b>	<b>1</b>
0.001 s	100 000	Dauer [s]	530.62	398.60	81.03	24.00	19.08	3.54	4.38
		Anteil [%]	100	75	15	5	4	1	1

die Dimension  $n_{\text{cell}} = 500$  und die Matrix der Polarisierungsspannungen hat die Größe  $500 \times 2$ . Innerhalb der  $n_{\text{mod}} = 50$  Module zeigen jeweils  $n_{\text{th}} = 10$  Zellen thermische Wechselwirkungen. Die 500 Zellen besitzen die SOC- und temperaturabhängigen Parameter der PAN-Zelle (Abbildung 3.6). Die Tabellen 3.1, 3.3 und 3.5 zeigen die Parameter des Alterungs- und Temperaturmodells sowie der Temperatur- und Stromverteilung. Die Zellparameter besitzen eine normalverteilte Variation. Die Simulation des Modells erfolgt für eine Zeit von  $t_{\text{sim}} = 100$  s mit den Abtastraten 1 Hz, 10 Hz, 100 Hz und 1 kHz. Tabelle 3.7 fasst die mit dem MATLAB Profiler ermittelten Ausführungszeiten zusammen. Neben der Gesamtausführungszeit sind auch die Ausführungszeiten für die einzelnen Teilmodelle angegeben. Die Untersuchung zeigt, dass das Modell-Framework in der vorliegenden Form für eine Simulationsdauer von 100 s bei einer Rate von 100 Hz 53.37 s benötigt. Damit eignet sich das elektrothermische Modell für die simulationsgestützte Entwicklung und Optimierung von Batteriesystemen und erlaubt die Erzeugung einer breiten Datenbasis für datengetriebene Diagnoseansätze. Zudem bildet die Performanz des Modells die Grundlage für die Entwicklung einer zellindividuelle Echtzeitsimulation des gesamten Batteriepacks. Da die elektrischen, thermischen und Alterungsmodelle deutlich unterschiedliche Zeitkonstanten haben, ist eine Simulation mit unterschiedlichen Zeitskalen grundsätzlich sinnvoll. Betrachtet man jedoch die Anteile der Teilmodelle an der Gesamtzeit, so nimmt die elektrische Simulation (Stromverteilung und elektrisches Modell) 79 %, die thermische Simulation (Temperaturverteilung und thermisches Modell) 16 % und die Alterungssimulation 4 % der Simulationsdauer ein. Da die elektrische Simulation die kleinsten Zeitkonstanten besitzt, würde eine Simulation mit unterschiedlichen Zeitskalen die Simulationszeit nur um maximal 21 % reduzieren. Methoden mit adaptiver Schrittweite und parallelem Rechnen bieten deshalb mehr Potential, sofern die Simulationsgeschwindigkeit des Modells weiter gesteigert werden soll.



**Abbildung 3.13:** Exemplarische Darstellung der zellindividuellen, internen Zustände anhand eines 108s3p-Batteriesystems

## 3.6 Graphische Oberfläche des Batteriemodells

Um die internen Zustände und die Effizienz des Modells zu demonstrieren, fasst die Arbeit das Modell-Framework in einer grafischen Oberfläche zusammen. Abbildung 3.13 zeigt exemplarisch ein Batteriesystem mit  $n_{\text{cell}} = 324$  Zellen in einer 108s3p-Konfiguration. Die  $n_{\text{mod}} = 27$  Module besitzen jeweils 12 Zellen, deren Parameter auf den PAN-Zellen aus Abbildung 3.6 basieren. Die graphische Oberfläche stellt die messbaren und nicht-messbaren Variablen aller Zellen übersichtlich dar. Zu den messbaren Größen gehört die Temperatur, die Spannung und der Strom. Die nicht-messbaren Größen beinhalten beispielsweise den Ladezustand (Abbildung 3.13a), die Polarisations- und Ruhespannung (Abbildung 3.13b), die Kerntemperatur, den Innenwiderstand (Abbildung 3.13c), die Kapazität sowie den Fehler- oder Alterungszustand (Abbildung 3.13d) der Zellen. Die graphische Oberfläche erleichtert zudem die Initialisierung oder eignet sich, um die Auswirkung von initialen Parametervariationen oder

Fehler zu untersuchen. Durch Auswahl einer beliebigen Zelle (siehe Anhang, Abbildung A.6) ist es möglich, den zeitlichen Verlauf der entsprechenden Variablen zu beobachten. Dies unterstützt bei der Systemauslegung und der Abschätzung der Auswirkung von Fehlern. So zeigt Abbildung A.6 anhand eines ISC in Zelle 141 exemplarisch den Anstieg der Oberflächentemperatur der betroffenen Zelle sowie die Propagation der Wärme auf die benachbarten Zellen innerhalb des Moduls. Das Dropdown-Menü unterhalb der Batteriepack-Visualisierung erlaubt den Einblick in die weiteren messbaren und nicht-messbaren Größen. Die aus dem Modell generierten Daten eignen sich für die Entwicklung und den Test der in den Kapiteln 4 und 5 vorgestellten Fehlerdiagnosealgorithmen.

### 3.7 Ergebnisse und Fazit zum Batteriepackmodell

Die experimentelle Parametrierung des Batteriemodells bestätigt die Notwendigkeit von Temperatur- und SOC-abhängigen Parametersätzen für die Zellen. So verdoppelt sich beispielsweise der Innenwiderstand der Zellen bei einer Temperatur von 15 °C im Vergleich zu 45 °C. Auch im niedrigen SOC-Bereich ist ein signifikanter Anstieg von mehr als 50 % im Vergleich zum mittleren beziehungsweise hohen SOC-Bereich zu beobachten. Selbst die Ruhespannung ändert sich bei einer Temperaturänderung um bis zu 0.2 mV/K. Eine Validierung des Modells bei verschiedenen Temperaturen mit einem dynamischen Stromprofil, das den gesamten SOC-Bereich abdeckt, bestätigt die Plausibilität der identifizierten Parameter. Der RMSE beträgt für die PAN-Zelle stets weniger als 8 mV und für die SMG-Zelle weniger als 15 mV. Um die Eignung zur Fehlersimulation zu untersuchen, werden auf einem Modulprüfstand die Fehlerfälle *erhöhter Kontaktwiderstand*, *externer Kurzschluss* und *interner Kurzschluss* emuliert und parallel dazu im Modell simuliert. Ein Abgleich der Messdaten mit den simulierten Größen bestätigt, dass das Modell geeignet ist, Fehlerfälle zu simulieren. Jeder der drei simulativ und experimentell untersuchten Fehlerfälle führte zu einer inhomogenen Strom- und Temperaturverteilung innerhalb des Moduls. Diese Inhomogenitäten führten im Modell wiederum zu einer inhomogenen Alterung hinsichtlich der Kapazitätsabnahme und des Innenwiderstandsanstiegs.

Bei der Entwicklung des Systemmodells hat sich herausgestellt, dass gerade für die Simulation großer Batteriesysteme mit mehreren hundert Einzelzellen, die elektrisch-thermisch interagieren, die Recheneffizienz des Modells ein signifikanter Faktor ist. Die Matrix-Vektor-basierte Struktur des Modell-Frameworks erlaubt eine Simulation des Batteriepacks auf einem regulären mobilen Prozessor mit einer Frequenz von 100 Hz. Um das weitere Optimierungspotential abzuschätzen, untersucht Abschnitt 3.5.4 die Berechnungsdauer der entwickelten Teilmodelle anhand eines 500-Zellen-Beispielsystems. Die Untersuchung zeigt, dass die Berechnung der Stromverteilung im Batteriepack etwa 75 % der Simulationsdauer einnimmt. Zusammen mit dem elektrischen Modell beträgt der Anteil, je nach Simulationsfrequenz,



---

knapp 80 %. Bei den elektrischen Effekten handelt es sich, im Vergleich zu den thermischen und Alterungseffekten, um die Effekte mit der kleinsten Zeitkonstante. Soll die Simulationsdauer also weiter optimiert werden, so liegt das größte Potential in einer Parallelisierung des elektrischen und des Stromverteilungsmodells.



## 4 Datengetriebenes Zellmonitoring zur Diagnose interner Kurzschlüsse

Basierend auf einer Analyse der bekannten Literatur im Bereich der datengetriebenen Fehlerdiagnose und der Erkennung von internen Kurzschlüssen (Abschnitt 4.1), stellt dieses Kapitel einen neuartigen Diagnoseansatz in Batteriesystemen vor. Grundlage zur Validierung des entwickelten Verfahrens bilden experimentelle und simulierte Daten, die aus Prüfständen, realen Fahrzeugen und dem in Kapitel 3 vorgestellten Modell basieren. Abschnitt 4.2 stellt in diesem Zusammenhang experimentelle Ansätze zur Untersuchung interner Kurzschlüsse und die verwendete Datengrundlage vor. Die Anwendung des datengetriebenen Ansatzes erfordert eine robuste Vorverarbeitung der Spannungssignale (Abschnitt 4.3). Basierend auf den vorverarbeiteten Daten stellt Abschnitt 4.4 das lineare PCA-basierte Detektionsverfahren vor, das um eine Fehlerisolierung und eine Anpassung an nicht-stationäres Verhalten erweitert wird. Auf die Adaption an Nichtlinearitäten, wie sie mit zunehmender Alterung der Batteriesysteme zu beobachten sind, geht Abschnitt 4.5 ein. Zudem thematisiert der Abschnitt die Rechenkomplexität des Algorithmus und eine optimale Parameterwahl sowie die Fehlerisolierung.

Die Beiträge dieses Kapitels basieren auf den Veröffentlichungen [235, 239, 240, 241].

### 4.1 Stand der Technik

Während Abschnitt 4.1.1 auf die bekannte Literatur zur datengetriebenen Fehlerdiagnose in Batteriesystemen eingeht, untersucht Abschnitt 4.1.2 speziell Verfahren, die auf die Detektion interner Kurzschlüsse angewandt werden.

#### 4.1.1 Fehlerdiagnose mit datengetriebenen Methoden

Neben Zustandsschätzung, Zell-Balancing und Thermomanagement ist die Fehlerdiagnose eine zentrale Aufgabe des BMSs [178, 260]. Das BMS muss sofort vor einem aufgetretenen oder prognostizierten Batteriefehler warnen und je nach Schwere des Ereignisses entsprechend reagieren. Die Literatur diskutiert verteilte BMSs, wie sie auch IBSs besitzen, als einen Ansatz zur Erhöhung der Batteriesicherheit [164, 177, 210]. Da in IBSs jede Zelle über ihre eigene Recheneinheit verfügt, sind insbesondere auch Strom-, Spannungs- und Temperatursignale

für jede einzelne Zelle verfügbar. Ein robuster und simpler Ansatz ist die Überwachung der Zellen auf Über-/Unterspannung, Übertemperatur und Überlade-/ Entladestrom. Rein schwellenwertbasierte Methoden erkennen Fehler jedoch sehr spät. Steigt beispielsweise die Temperatur einer Zelle schnell an, so kann es auch bei richtiger Reaktion nach Überschreiten der Übertemperaturgrenze zum thermischen Durchgehen kommen. Nach der BMS-Norm der Internationalen Elektrotechnischen Kommission muss ein BMS über ein Frühwarnsystem für ungesunde Batterien verfügen [99]. Die Kernaufgabe der Fehlerdiagnose besteht also darin, Fehler so früh wie möglich zu erkennen, bevor die kritischen Grenzen erreicht werden. Die zunehmende Anzahl von Sensoren bietet Chancen und Herausforderungen. Erstere bestehen in einer höheren Redundanz, der Möglichkeit, fehlerhafte Sensoren zu kompensieren sowie einer einfacheren und besseren Isolierung von Fehlern [238, 250]. Die Herausforderung besteht darin, dass mit zunehmender Anzahl von Komponenten auch die Ausfallwahrscheinlichkeit einer Komponente im Gesamtsystem steigt.

Während die Literatur zu modellbasierten Fehlerdiagnose-Methoden in Batteriesystemen umfangreich ist, sind datengetriebene Methoden weniger verbreitet. Hu, Zhang u. a. fassen die Literatur auf dem Gebiet der erweiterten Batteriefehlerdiagnose in einer umfassenden Übersicht zusammen [123]. Signal- beziehungsweise datenbasierte Ansätze haben erst in den letzten Jahren zunehmende Aufmerksamkeit erhalten [278]. Kong, Zheng u. a. diagnostizieren ISCs basierend auf Variationen in der verbleibenden Ladekapazität bis zur vollständigen Ladung zwischen den Batteriezellen [148]. Die Autoren ermitteln die verbleibende Ladekapazität aus dem Ladespannungsverlauf der Zellen, weshalb die Methode nur während des Ladevorgangs anwendbar ist. Xia, Shang u. a. analysieren die Zellspannungen mithilfe des Korrelationskoeffizienten [299]; Li und Wang verwenden den Intraklassen-Korrelationskoeffizienten [162]. Die korrelationsbasierten Ansätze ermöglichen die Erkennung eines Kurzschlussfehlers einer Batterie durch Messung des Spannungsabfalls bei Abweichung vom allgemeinen Trend. Um die Dauer der Fehlerspeicherung zu verlängern, verwenden beide Ansätze eine Filterung mit gleitenden Fenstern. Die korrelationsbasierten Ansätze sind jedoch anfällig für Rauschen, insbesondere bei niedriger Anregung. Kang, Duan u. a. verwenden ebenfalls einen korrelationsbasierten Ansatz zur Isolierung von Kurzschlussfehlern, Spannungssensorfehlern und Kontaktfehlern [137, 138]. Dazu verwenden sie eine nicht-redundante, kreuzartige Mess-topologie, die aus überlappenden Spannungsmessungen von seriellen Zellen besteht. Eine sensortopologiebasierte Fehlerdiagnose wurde zuvor auch von Xia, Nguyen u. a. verwendet, um die Fehlerisolierung zu erweitern und eine fehlertolerante Messung zu realisieren [297, 298]. Obwohl topologiebasierte Methoden Vorteile bei der Isolierung verschiedener Fehler haben, sind sie nur auf Batteriesysteme anwendbar, bei denen eine überlappende Spannungsmessung von seriellen Zellen existiert. Eine weitere Art von datengetriebenen Methoden zur Fehlerdiagnose in Batteriesystemen nutzt die Entropietheorie. Unter Verwendung der Shannon-Entropie isoliert Zheng, Ouyang u. a. Fehler, die auf eine Erhöhung des Innenwiderstands zurückzuführen sind, von Fehlern, die auf einer Erhöhung des Kontaktwiderstands

beruhen [327]. Die Autoren wenden die entwickelte Methode auf einen Batteriepack mit 96 seriellen Zellen an. Die Detektion von Zellverbindungsfehlern in [272, 312] basiert ebenfalls auf der Anwendung der Shannon-Entropie. Ma, Wang u. a. schlagen die Verwendung eines modifizierten Z-Score-Tests vor, um einen erhöhten Kontaktwiderstand zu erkennen [183]. Die Entropie wird auch in [118, 170, 289] zur Spannungsfehlerdiagnose und in [117] zur Prognose des thermischen Durchgehens von Zellen verwendet. Entropiebasierte Ansätze erweisen sich als effektives Werkzeug zur Batteriefehlererkennung und -isolierung. Bei verrauschten Signalen variiert die Genauigkeit und Empfindlichkeit jedoch stark in Abhängigkeit von dem verwendeten Entropiemaß [312]. Eine höhere Diagnosegenauigkeit erhöht auch die Rechenkosten [278], was eine besondere Herausforderung für BMS-Anwendungen darstellt. Für die Spannungsfehlerdiagnose verwenden Chen, Xu u. a. sowie Zhao, Liu u. a. Algorithmen zur Ausreißerererkennung [32, 322]. Während der Ansatz von Chen, Xu u. a. auf einer modellbasierten Systemidentifikation basiert, schlagen Zhao, Liu u. a. eine mehrstufige  $3\sigma$ -Screening-Strategie vor, um eine Fehlerdiagnose zu realisieren [32, 322]. Die Validierung der Methode basiert auf Daten des Beijing Electric Vehicles Monitoring and Service Centers. Yang, Xiong u. a. verwenden ein Random-Forest-Verfahren, um Elektrolytleckagen von Zellen mit externem Kurzschluss zu erkennen [309]. Die Diagnose basiert auf der Entladekapazität und dem maximalen Temperaturanstieg. Yao, Xiao u. a. verwenden Wavelet-Netze für die Erkennung von Kontaktfehlern [313]. Eine diskrete Wavelet-Zerlegung und Rekonstruktion verarbeitet die Sensordaten, um Messfehler und Rauschen zu reduzieren. Basierend darauf extrahiert der Ansatz aus den resultierenden Daten charakteristische Features für das Training des neuronalen Netzes.

### 4.1.2 Detektion von internen Kurzschlüssen

ISCs weisen in den frühen Entwicklungsstadien oft einen hohen elektrischen Widerstand auf, sodass die Auswirkung des Kurzschlussfehlers gering und schwer zu erkennen ist. In dieser frühen Phase werden die Kurzschlüsse als Soft-ISCs bezeichnet. Wird ein Soft-ISC nicht erkannt, so kann er im weiteren Verlauf zu einem niederohmigen harten ISC führen [257]. Selbst wenn ein thermisches Durchgehen unvermeidbar ist, kann Schaden von den Passagieren und der Umgebung abgewendet werden, wenn eine Frühwarnung erfolgt. Aus diesem Grund hat sich die Früherkennung von ISC zu einem aktiven Forschungsgebiet entwickelt. Ein gängiger Ansatz in der Literatur ist die modellbasierte Schätzung von Fehlermerkmalen unter Verwendung der Recursive-Least-Squares-Methode (RLS-Methode), um eine Diagnose abzuleiten [75, 76, 211, 256, 257, 321]. Fehlermerkmale sind beispielsweise der Ohmsche Widerstand, die Kapazität oder SOC-Unterschiede zwischen den Zellen. Einige dieser Merkmale schätzen bereits heutige, konventionelle BMSs und stehen für die Diagnose zur Verfügung. Andere modellbasierte Schätzverfahren zur ISC-Detektion verwenden robuste Zustandsbeobachter [195, 305] oder Kalman-Filter [87, 237, 238, 255]. Gao, Zheng u. a. schätzen die

Parameter eines Mean-Difference-Modells und Seo, Goh u. a. schätzen Ruhespannungsdifferenzen zur ISC-Erkennung [87, 255]. Lai, Yi u. a. verwenden den Korrelationskoeffizienten zur Fehlerdiagnose nach einer Kalman-Filter-basierten Parameterschätzung [156]. Die vorgenannten modellbasierten Methoden sind jedoch bei der Schätzung von Fehlermerkmalen immer von Modell- oder Parameterunsicherheiten betroffen. Diese Unsicherheiten wirken sich negativ auf die Empfindlichkeit gegenüber Soft-ISCs in einer frühen Phase aus. Weiterhin können modellbasierte Methoden einen hohen Parametrierungsaufwand aufweisen und sind teilweise von Zellinkonsistenzen betroffen. Neben den vorgestellten modellbasierten Methoden gibt es auch datengetriebene Ansätze zur ISC-Erkennung. ISCs werden in [137, 162, 299] anhand des Korrelationskoeffizienten diagnostiziert. Die korrelationsbasierten Methoden sind unempfindlich gegenüber Zellinkonsistenzen und eine analytische Redundanz wie bei modellbasierten Methoden ist nicht erforderlich. Messrauschen kann jedoch die Detektionsperformance verschlechtern [123]. Außerdem ist die Methode von Kang, Duan u. a. nur für Batteriesysteme mit verschachtelten Spannungsmessungen geeignet [137]. Andere datengetriebene Methoden verwenden die Shannonsche Informationstheorie [258, 326]. Die Entropie-Methode ist ein Werkzeug, um den Grad der Zufälligkeit oder Unordnung von Zeitreihendaten eines Systems zu beschreiben und wird in der Literatur häufig als Methode zur Fehlerdiagnose eingesetzt. Zheng, Lu u. a. verwenden die Transinformation, um eine Zelle mit geringer Kapazität von einer ISC-Zelle zu unterscheiden [326]. Die Empfindlichkeit von entropiebasierten Methoden nimmt jedoch bei verrauschten Signalen deutlich ab [312]. Kong, Zheng u. a. verwenden die Variationen der verbleibenden Ladekapazität zwischen den Zellen zur Kurzschlussdiagnose [148]. Die Methode ermöglicht auch die Abschätzung des Widerstands des ISCs, ist aber nur während der Ladephase anwendbar [148].

### **Einordnung der Verfahren zur Detektion interner Kurzschlüsse**

Modellbasierte Methoden erkennen Fehler aufgrund von Abweichungen zwischen Modell und Messdaten oder aufgrund der Änderung von Modellparametern selbst, wie beispielsweise dem SOC oder dem Innenwiderstand. Je höher die gewünschte Empfindlichkeit, desto höher sind die Anforderungen an das Modell, um alle elektrischen, thermischen und mechanischen Zelleigenschaften und die Alterung abzubilden. Damit steigt die Komplexität des Modells. Außerdem ist die Genauigkeit immer durch Parameterunsicherheiten begrenzt. Der in dieser Arbeit verfolgte Ansatz basiert direkt auf den Variationen der Zellspannungen, die jedes konventionelle BMS misst. In homogenen Batteriesystemen haben alle Zellen ähnliche elektrische, thermische und mechanische Eigenschaften sowie das gleiche kalendarische Alter. Die seriellen Zellen eines konventionellen Batteriesystems werden über ihre Lebensdauer mit dem gleichen Lastprofil betrieben und sind ähnlichen (Umgebungs-)Temperaturen ausgesetzt, was bedeutet, dass sie auch einen ähnlichen SOH aufweisen. Die verbleibenden Spannungsdifferenzen aufgrund von Anfangsparametervariationen, inhomogener Temperaturverteilung und inhom-


gener Alterung weisen jedoch ein komplexes Verhalten auf. Um die Spannungsdifferenzen als Fehlermerkmal zu verwenden, ist in der bekannten Literatur entweder die Schätzung eines Differenzmodells [87, 327] oder ein großer Schwellenwert für die Spannungsdifferenzen [156] erforderlich, was zu einer langen Detektionszeit (Detection-Time, DT) oder einer hohen Fehlalarmrate (False-Alarm-Rate, FAR) führt. An dieser Stelle setzt die vorliegende Arbeit an, die die Verteilung der Spannungsdifferenzen im fehlerfreien Fall lernt, um Anomalien im Test zu detektieren.

## 4.2 Versuchsaufbauten und Datengrundlage

Die Validierung von Algorithmen zur Fehlerdiagnose erfordert Daten, die den Fehler enthalten. Da die Verfahren dieser Arbeit auf den Zellspannungen basieren, geht Abschnitt 4.2.1 auf die Spannungseffekte interner Kurzschlüsse ein und stellt experimentelle Ansätze vor, die sich zur Generierung von Fehlerdaten eignen. Die Datengrundlage bilden Daten von Prüfständen, realen Fahrzeugen und Modelldaten. Abschnitt 4.2.6 fasst die Datengrundlage zusammen und bewertet diese.

### 4.2.1 Spannungseffekte interner Kurzschlüsse und experimentelle Ansätze

Wie in Abschnitt 2.3.1 beschrieben, beeinflussen ISCs sowohl die messbaren Größen, wie den Strom, die Spannung und die Temperatur, als auch die internen Zustände, wie den Innenwiderstand, den Ladezustand oder die Kapazität einer Zelle. Es stellt sich deshalb die Frage nach dem optimalen Feature für das datengetriebene Monitoring. Die Änderung des Stroms, wie in Abbildung 2.14a gezeigt, ist nur in Systemen mit parallelen Zellen zu beobachten, die zudem eine Strommessung je Zelle besitzen. Konventionelle Batteriesysteme und insbesondere rein seriell-verschaltete Systeme (Xs1p-Konfiguration) besitzen dagegen nur eine redundante Messung des Gesamtstroms. Die Temperaturmessung erfolgt in der Regel an kritischen Punkten in den Batteriemodulen und häufig nicht zellindividuell. Zudem handelt es sich bei den Messungen um Oberflächentemperaturen, die die Kerntemperatur der Zellen verzögert repräsentieren, was einen Nachteil für die Früherkennung von ISCs darstellt. Obwohl der Ohmsche Innenwiderstand ein vielversprechendes Merkmal zur ISC-Erkennung darstellt, zeigt sich anhand Gleichung (2.16), dass eine signifikante Änderung erst bei einem fortgeschrittenen ISC zuverlässig zu detektieren ist. In einer frühen Phase überwiegt die Abhängigkeit des Ohmschen Innenwiderstands von der Temperatur und dem Ladezustand (siehe Abbildungen 3.6 und 3.7,  $R_0$ ). Vergleicht man hingegen den kompletten Verlauf der Impedanz über verschiedene Frequenzen, die die EIS ermittelt, so lassen sich aussagekräftigere Features zur Erkennung von ISC-Zellen finden [147]. Bei der Schätzung des Ladezustands oder der Kapazität als Fehlermerkmale überwiegen in der frühen Phase die Modellunsicherheiten




**Abbildung 4.1:** Unterscheidung kleinerer und größerer ISCs sowie zwischen Soft- und Hard-ISCs (angelehnt an [169]).

den Einfluss des ISCs. Signifikante Änderungen sind erst im späteren Verlauf des ISCs zu beobachten. Die an den Zellterminals gemessene Spannung hingegen gibt einen direkten Einblick in die Vorgänge innerhalb der Zelle. Zudem messen konventionelle BMSs die Spannungen aller seriellen Zellen, da dies für das Zell-Balancing erforderlich ist [178]. Bei der Zellspannung ist jedoch zu beachten, dass es sich dabei um eine Überlagerung sehr vieler Effekte handelt. Wie Gleichung (3.80) zeigt, setzt sich die gemessene Spannung aus der Ruhespannung, dem Ohmschen Spannungsabfall und der dynamischen Polarisationsspannung zusammen. Dazu kommen Hysterese- und Entropieeffekte sowie Inhomogenitäten innerhalb des Zellwickels [160], weshalb die Aussagekraft der Terminal-Spannung und damit die beobachtbaren Effekte von Soft-ISCs mit steigender Zellgröße abnehmen. Insbesondere großformatige Zellen erfordern deshalb ein ISC-Detektionsverfahren mit einer hohen Sensitivität.

Betrachtet man die Auswirkungen von ISCs auf die Zellspannung näher, so lassen sich verschiedene Stadien von ISCs und dem korrespondierenden Spannungsverhalten unterscheiden. Wie Abbildung 4.1 zeigt, gehen ISCs mit Spannungseinbrüchen einher, die aufgrund von Kurzschlüssen zwischen Anode und Kathode durch den Separator resultieren (siehe Abschnitt 2.3.1). Liu, Jia u. a. unterscheiden kleinere und größere ISCs [169]. Während ein größerer ISC gleich zu einem harten ISC, verbunden mit einem großem Spannungseinbruch und einer hohen Wärmegenerierung (Abbildung 4.1, Verhalten II) führen kann, verschwinden kleinere ISCs häufig reversibel, ohne einen größeren Zellschaden zu verursachen [318]. Bis auf eine geringfügige Selbstentladung ist an der Zelle im Anschluss keine Auffälligkeit mehr zu beobachten (Abbildung 4.1, Verhalten I). Neben diesen beiden Verhaltensweisen können sich nach einem größeren ISC auch die Spannungseinbrüche und Entladungen wiederholen und schließlich zu einem harten ISC führen (Abbildung 4.1, Verhalten III). Liu, Jia u. a. differenzieren kleinere und größere ISCs anhand des Kurzschlussstyps und Soft- beziehungsweise Hard-ISCs daran, ob Stromableiter und Separator schmelzen [169, 318].

Ziel dieser Arbeit ist es, Soft-ISCs zu erkennen, bevor ein harter ISC und eine extensive Wärmegenerierung entstehen. In diesem Zusammenhang lassen sich drei Stadien von






**Abbildung 4.2:** Anfangs-, mittlere und Endphase eines ISCs (angelehnt an [169]).

ISCs, basierend auf der messbaren Spannung und der Zelltemperatur, unterscheiden (siehe Abbildung 4.2) [169]. In der Anfangsphase zeigt der ISC ein selbstlöschendes Verhalten, begleitet von einer langsamen Abnahme der Spannung durch die Selbstentladung und einer geringen Wärmegenerierung. Dieses Verhalten äußert sich in der mittleren Phase stärker. Die Endphase eines ISCs äußert sich aufgrund des Versagens des Separators durch eine unaufhaltbare, massive Wärmegenerierung, die Nebenreaktionen zusätzlich verstärken. Ziel der Früherkennung ist es, ISCs möglichst in der Anfangsphase oder spätestens in der mittleren Phase zu detektieren.

Um ISCs experimentell auszulösen oder ihr Verhalten zu emulieren haben sich in der Literatur eine Vielzahl an Verfahren etabliert. Zhang, Wei u. a. stellen eine Auswahl an Methoden vor und diskutieren ihre Vor- und Nachteile [318]. Um einen ISC zu induzieren, bietet es sich entweder an, Zellen zu präparieren oder den ISC durch Über(ent-)laden, Druck, Anheizen oder über einen Laserstrahl auszulösen. Die Verfahren unterscheiden sich in ihrer Reproduzierbarkeit, Kontrollierbarkeit und Komplexität. Präparierte Zellen, beispielsweise, können echte ISCs zwar gut nachbilden, die Kurzschlüsse sind aber schwer zu kontrollieren und zu reproduzieren. Zudem verhalten sich die präparierten Zellen meist schon zu Beginn ihres Lebens auffällig [318]. Eine in der Literatur weit verbreitete Methode, die sich durch ihre geringe Komplexität und hohe Reproduzierbarkeit sowie Kontrollierbarkeit auszeichnet, ist die Emulation des ISCs mit einem externen Widerstand [87, 156, 211, 257, 326]. Der Nachteil dieser Methode besteht allerdings darin, dass die Effekte des ISCs im Zellwickel nicht abgebildet werden und auch die Wärmegenerierung im externen Widerstand anstatt an einem lokalen Punkt innerhalb der Zelle entsteht. Da sich die Algorithmen dieser Arbeit auf die Zellspannung stützen, ist jedoch lediglich eine elektrische Emulation des ISCs von Bedeutung. Zudem bestätigen Zhang, Wei u. a., dass sich diese experimentelle Emulationsmethode vor allem im frühen Stadium eines ISCs eignet [318], auf das sich die nachfolgend vorgestellten Methoden konzentrieren. Unterschiedliche Widerstände erlauben zudem, verschiedene ISC-

**Tabelle 4.1:** Ermittelte Zellkapazitäten der 12 PAN-Zellen (1 C-Entladung bei 25 °C).

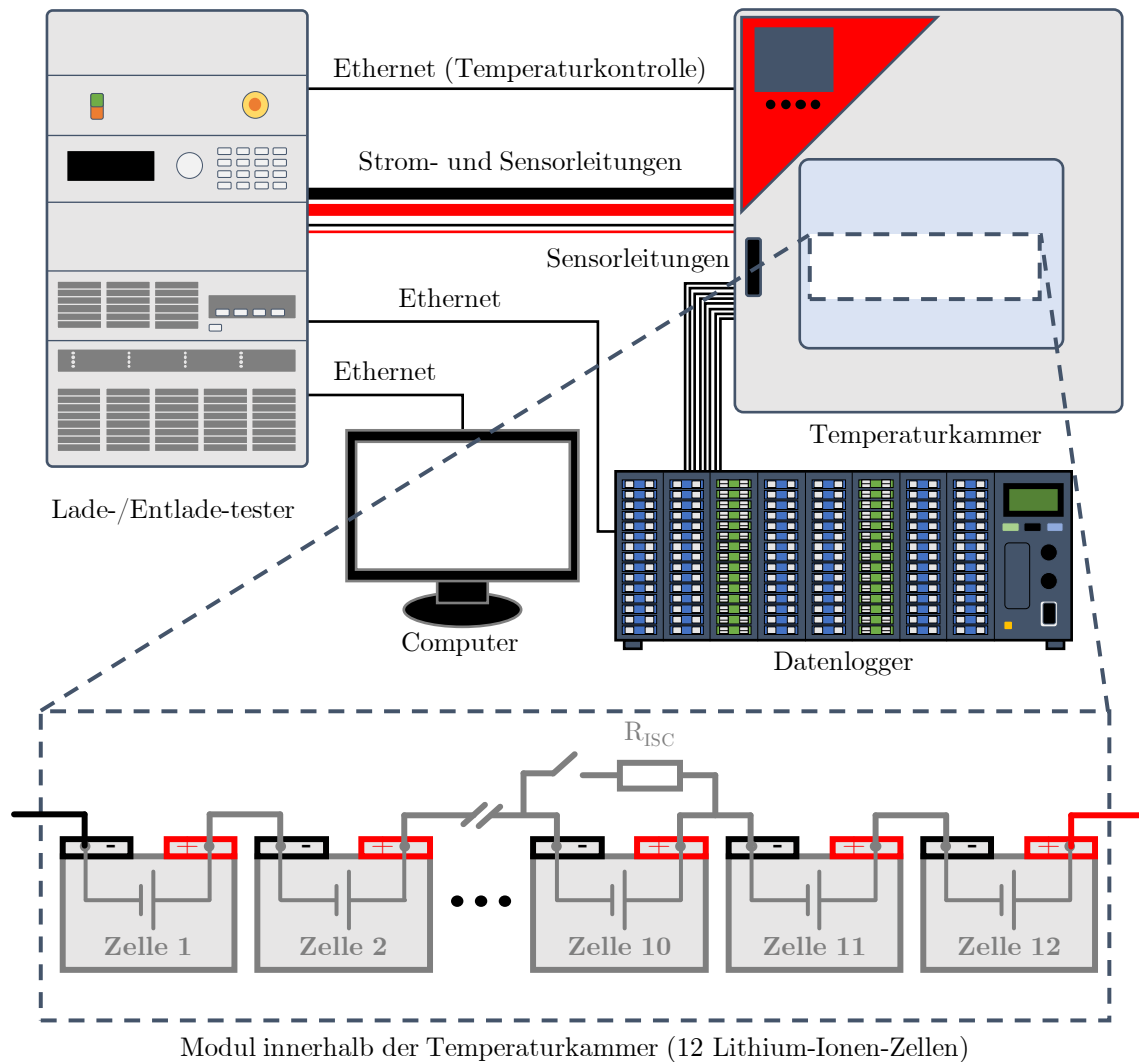
Zelle	1	2	3	4	5	6
Kapazität [Ah]	21.84	21.91	21.95	21.63	21.71	21.19
Zelle	7	8	9	10	11	12
Kapazität [Ah]	21.22	21.47	21.48	21.93	21.82	21.78

**Abbildung 4.3:** Ermittelte Innenwiderstände (10 Hz) der PAN-Zellen bei 25 °C.

Phänomene nachzubilden und den daraus resultierenden unterschiedlichen Spannungsabfällen Rechnung zu tragen. Die Kenntnis des externen Widerstandswerts ermöglicht darüber hinaus eine optimale Reproduzierbarkeit.

#### 4.2.2 Versuchsaufbau und Messergebnisse mit den PAN-Zellen


Ein seriell verschaltetes Batteriemodul, bestehend aus 12 Lithium-Ionen-Zellen, ermöglicht die experimentelle Validierung der in den Abschnitten 4.4 und 4.5 entwickelten Methoden. Bei den Zellen handelt es sich um die in Tabelle 2.1 vorgestellten prismatischen PAN-Zellen mit einer NMC/Graphit-Chemie. Die untere beziehungsweise obere Cut-Off-Spannung beträgt 3 V beziehungsweise 4.1 V. Die Zellen mit einer anfänglichen Nennkapazität von 25 Ah alterten zehn Jahre lang kalendarisch und anschließend zyklisch im Modulverbund. Tabelle 4.1 zeigt die Kapazitäten der 12 Zellen nach einer 1 C-Entladung bei 25 °C. Die Kapazitäten liegen im Bereich von 21.19 Ah bis 21.95 Ah, was einem SOH von 84.8 % bis 87.8 % bezogen auf die Nennkapazität entspricht. Die Innenwiderstände bei 25 °C, ermittelt mit der Least-Squares-Methode, zeigt Abbildung 4.3. Die beobachteten Ohmschen Widerstände zeigen die typischen Verläufe mit einem Anstieg im niedrigen SOC-Bereich, wie sie auch in Abbildung 3.6 zu



**Abbildung 4.4:** Schematischer Aufbau des Prüfstands und des PAN-Moduls.

erkennen sind. Die Widerstände bei 50 % SOC variieren zwischen  $1.15 \text{ m}\Omega$  und  $1.31 \text{ m}\Omega$ . Die Parametervariationen liegen damit im Rahmen üblicher Parametervariationen für BEVs [12, 252]. Dies ermöglicht eine experimentelle Validierung in Gegenwart von Parametervariationen, wie sie während des Lebenszyklus von BEVs auftreten.


Abbildung 4.4 zeigt schematisch den Prüfstands Aufbau und Abbildung 4.5 den mechanischen Aufbau des Batteriemoduls. Der Test des Batteriemoduls erfolgt in einem BINDER-Temperaturschrank bei einer konstanten Temperatur von  $25^\circ\text{C}$ . Ein Chroma-Modul-Lade/Entladetester (250 A, 60 V) liefert die Stromanregung. Der Tester misst zudem die Gesamtspannung und den Gesamtstrom des Moduls mit einer Auflösung von 2 mV beziehungsweise 5 mA bei einer Abtastrate von 10 Hz. Die Messung der Einzelzellspannungen und Temperaturen ermöglicht ein Hioki 8423 Datenlogger. Die Spannungsaufösung des Loggers beträgt 0.5 mV und die gewählte Abtastrate ist 10 Hz. Der Datenlogger kommuniziert mit dem Chroma-Tester, um einen Betrieb aller Zellen im sicheren Spannungs- und



**Abbildung 4.5:** Mechanischer Aufbau des PAN-Moduls und Modulverspannung.

Temperaturbereich zu garantieren. Die Zellen sind zu Beginn des Tests vollständig geladen und vortemperiert. Die dynamische Anregung der Zellen erfolgt mit einem Stromprofil, das auf dem WLTP-Fahrzyklus basiert. Der maximale Lade- und Entladestrom während des dynamischen Stromprofils beträgt  $+67.4\text{ A}$  beziehungsweise  $-68.8\text{ A}$ . Das Stromprofil wiederholt sich so lange, bis die erste Zelle die untere Cut-Off-Spannung von  $3\text{ V}$  erreicht hat. Dann folgt eine Ladung mit einem konstanten Strom von  $25\text{ A}$ . Sobald die erste Zelle die obere Cut-Off-Spannung von  $4.1\text{ V}$  erreicht hat, setzt sich die dynamische Entladung fort. Das beschriebene Entlade-Lade-Prozedere wiederholt sich kontinuierlich. Ähnlich wie in [87, 156, 211, 257, 326] emuliert ein externer Widerstand  $R_{\text{ISC}}$  den ISC. Da das Ziel der Methode ist, ISCs in einer frühen Phase zu erkennen, kommen für die ISC-Emulation hohe Widerstandswerte von  $R_{\text{ISC}} \in \{10\ \Omega, 100\ \Omega\}$  zum Einsatz.

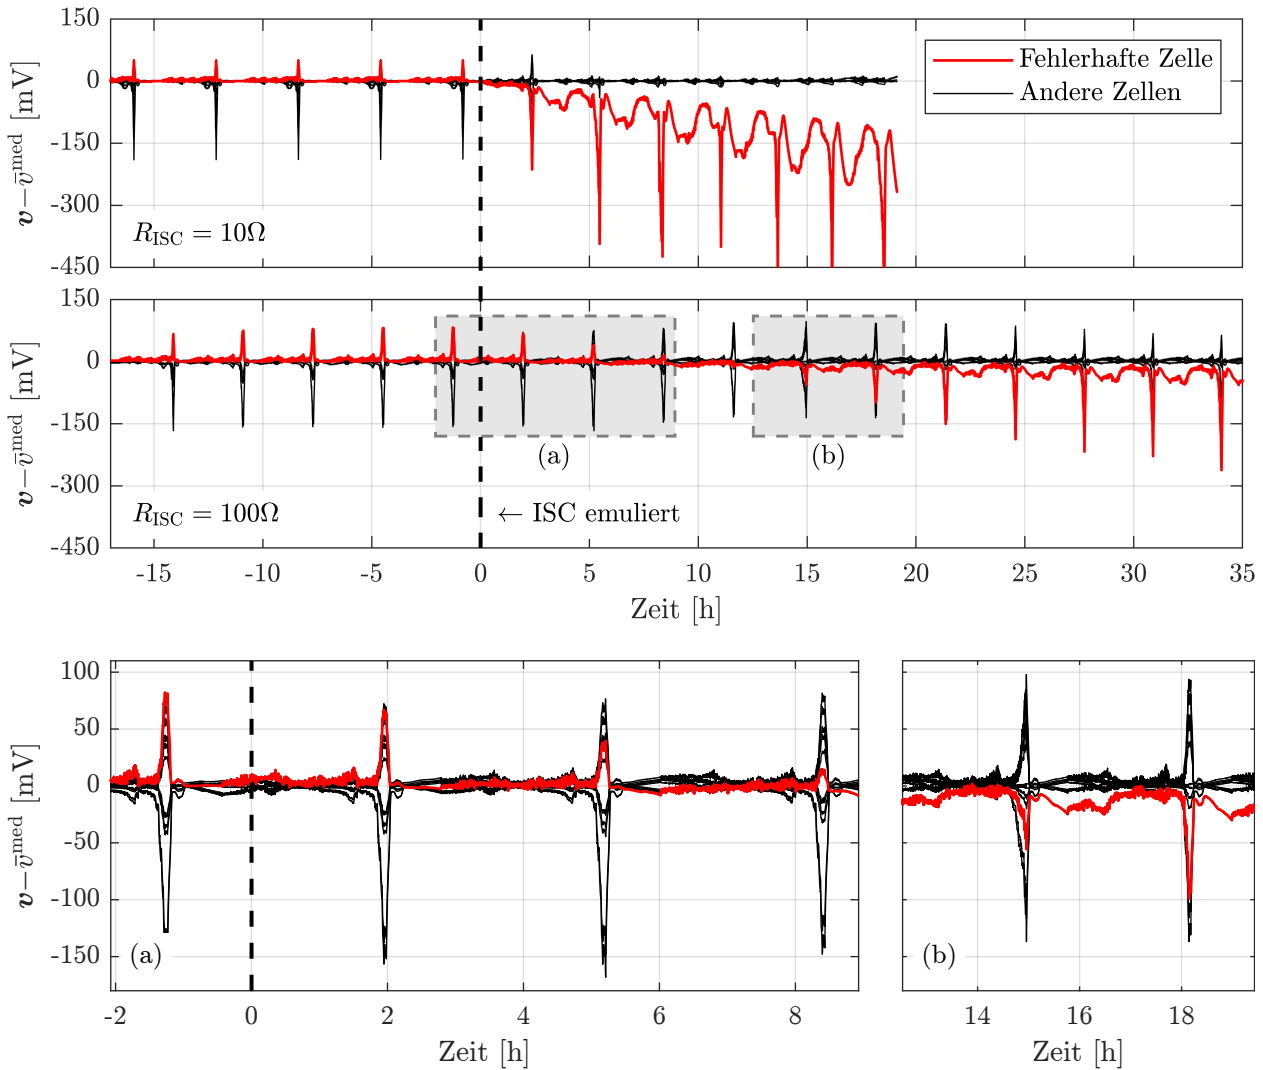
Abbildung 4.6 zeigt die gemessenen Spannungen der 12 seriellen Zellen über die Zeit. In den dargestellten Messdaten emuliert ein externer Widerstand von  $R_{\text{ISC}} = 100\ \Omega$  zum Zeitpunkt  $t = 17\text{ h}$  einen ISC in Zelle 10. Die Messungen aus Abbildung 4.6b mit dem blauen Hintergrund entsprechen  $2/3$  der fehlerfreien Daten vor Auftreten des ISCs und werden als Trainingsdaten ausgewählt ( $\Delta t = 11.3\text{ h}$ ). Abbildung 4.6a und Abbildung 4.6c zeigen Ausschnitte der Messung aus Abbildung 4.6b. Zur Vergleichbarkeit sind die Achsenskalen von Abbildung 4.6a und Abbildung 4.6c identisch. Abbildung 4.6a zeigt einen Abschnitt vor dem Auftreten des Fehlers, der auch Teil des Trainingsdatensatzes ist. Es ist zu erkennen, dass sich die Spannungen der Zellen im unteren SOC-Bereich deutlich voneinander unterscheiden. Dies liegt an den unterschiedlichen Kapazitäten der gealterten Zellen. Aufgrund der höheren Kapazität befindet sich Zelle 10 (rot markiert) im Vergleich zu den anderen Zellen in einem höheren Spannungsbereich. Nach Auftreten des ISCs bewegt sich die Zellenspannung zunächst in Richtung des Mittelwertes der anderen Zellen. Dies erschwert die Erkennung für Methoden, die beispielsweise die Differenz zwischen der stärksten und der schwächsten Zelle überwachen. Mit zunehmendem SOC verschwinden die Spannungsunterschiede zwischen den



**Abbildung 4.6:** Gemessene Zellspannungen für den Fall  $R_{\text{ISC}} = 100 \Omega$ . Die blau hinterlegten Messungen dienen als Trainingsdaten.

Zellen weitgehend. Dies ist in Abbildung 4.6c zu beobachten, die eine Messung im hohen SOC-Bereich nach Auftreten des ISCs zeigt. Die fehlerhafte Zelle 10 (rot) hat eine niedrigere Spannung im Vergleich zu den übrigen Zellen. Die Herausforderung von datengetriebenen Methoden, die nicht auf einer Schätzung des SOCs basieren, besteht darin, Fehler trotz Zellinkonsistenzen korrekt zu erkennen. Eine größere Spannungsdifferenz bedeutet nicht immer einen Fehler, während kleinere Spannungsdifferenzen bereits auf einen ISC hinweisen können.

Die Abweichungen der Einzelzellspannungen vom Median aller 12 Zellen sind in Abbildung 4.7 für beide Kurzschluss-Widerstandswerte von  $R_{\text{ISC}} = 10 \Omega$  und  $R_{\text{ISC}} = 100 \Omega$  dargestellt. Der Zeitpunkt  $t = 0 \text{ h}$ , zu dem der ISC emuliert wird, ist durch eine schwarze gestrichelte Linie markiert. Die 11 fehlerfreien Zellen sind schwarz dargestellt und die fehlerhafte Zelle ist rot markiert. Ideal identische und vollständig balancierte Zellen würden eine Spannungsdifferenz von konstant Null aufweisen. Aufgrund der Zellinkonsistenzen treten




**Abbildung 4.7:** Spannungsdifferenzen der PAN-Zellen bezogen auf die Median-Zelle für die Fälle  $R_{\text{ISC}} = 10\Omega$  und  $R_{\text{ISC}} = 100\Omega$ .

jedoch bereits während der fehlerfreien Messungen Abweichungen von über 150 mV gegenüber dem Median auf. Bei schlecht balancierten Zellen oder noch größeren Kapazitätsunterschieden können die Abweichungen auch mehrere 100 mV betragen (siehe Abschnitt 4.2.5). Im Falle des 10- $\Omega$ -Kurzschlusses ist ein rasches Absinken der Spannung der fehlerhaften Zelle zu beobachten, was nach einigen Stunden auch über Schwellenwertverfahren detektiert werden könnte. Besonders für den 100- $\Omega$ -Kurzschluss hätten Schwellenwertverfahren jedoch eine sehr lange Detektionszeit zur Folge. Wie in Abbildung 4.7b zu erkennen, liegt die Spannung der fehlerhaften Zelle auch 18 h nach Auftreten des ISCs zeitweise noch innerhalb der Spannungswerte der anderen Zellen. Ziel ist es jedoch, ISCs bereits in der frühen Phase, wie in Abbildung 4.7a dargestellt, zu detektieren.

Um die Aussagekraft der seriellen Zellspannungen zu verdeutlichen, werden die RMSEs zwischen jeder Zelle und den verbleibenden 11 Zellen im System berechnet. Abbildung 4.8





**Abbildung 4.8:** Box-Plots des RMSEs aller 12 PAN-Zellen untereinander während des Trainings.

zeigt die Abweichungen (RMSEs) der Zellspannungen untereinander in Form von Box-Plots für die beiden Fälle  $R_{ISC} = 10 \Omega$  und  $R_{ISC} = 100 \Omega$  während der fehlerfreien Trainingsphase. Wie Abbildung 4.8 zeigt, existiert in beiden Fällen für jede Zelle eine ähnliche Zelle, aus der Menge der 11 verbleibenden Zellen, deren Spannungsverlauf einen RMSE von weniger als 3 mV aufweist. Trotz der vorhandenen Parameterunterschiede und der geringen Anzahl an Zellen lassen sich also stets zwei Zellen finden, deren Spannungsverläufe über den gesamten Ladezustandsbereich einen Fehler in der gleichen Größenordnung aufweisen, wie aufwändige Modelle (siehe Tabelle 3.6).

### 4.2.3 Versuchsaufbau und Messergebnisse mit den SMG-Zellen

Der Versuchsaufbau für die Messungen mit den SMG-Zellen entspricht dem Prüfstand aus Abbildung 4.5. Den schematischen und mechanischen Aufbau des SMG-Moduls zeigt Abbildung 4.9. Die zylindrischen SMG-Zellen im 18650-Format des Herstellers Samsung haben eine Nennkapazität von 2.5 Ah (siehe Tabelle 2.1). Die untere und obere Cut-Off-Spannung ist 2.5 V beziehungsweise 4.2 V. Der maximale dauerhafte Entlade- und Ladestrom beträgt  $-20 \text{ A}$  beziehungsweise  $4 \text{ A}$ . Wie in Abbildung 4.9 zu erkennen, sind die Zellen auf Leiterplatten gelötet. Die Leiterplatten dienen als mechanische Halterung und sind zusätzlich mit einer Sicherung und Sensoren ausgestattet. Die serielle Verschaltung von 12 Leiterplatten bildet ein elektrisches Modul, das sich in einem BINDER-Temperaturschrank bei einer konstanten Temperatur von  $25 \text{ }^\circ\text{C}$  befindet.

Um realistische BEV-Bedingungen für den Betrieb des Moduls zu ermöglichen, erfolgt die Anregung mit unterschiedlichen Fahr- und Ladeprofilen. Der Modultester entlädt das Modul abwechselnd mit einem WLTP-basierten Stromprofil (maximale Ströme:  $-8.26 \text{ A}$  bis  $2.02 \text{ A}$ ) und einem Stromprofil basierend auf dem Artemis-Urban-Fahrzyklus (AU-Fahrzyklus) mit

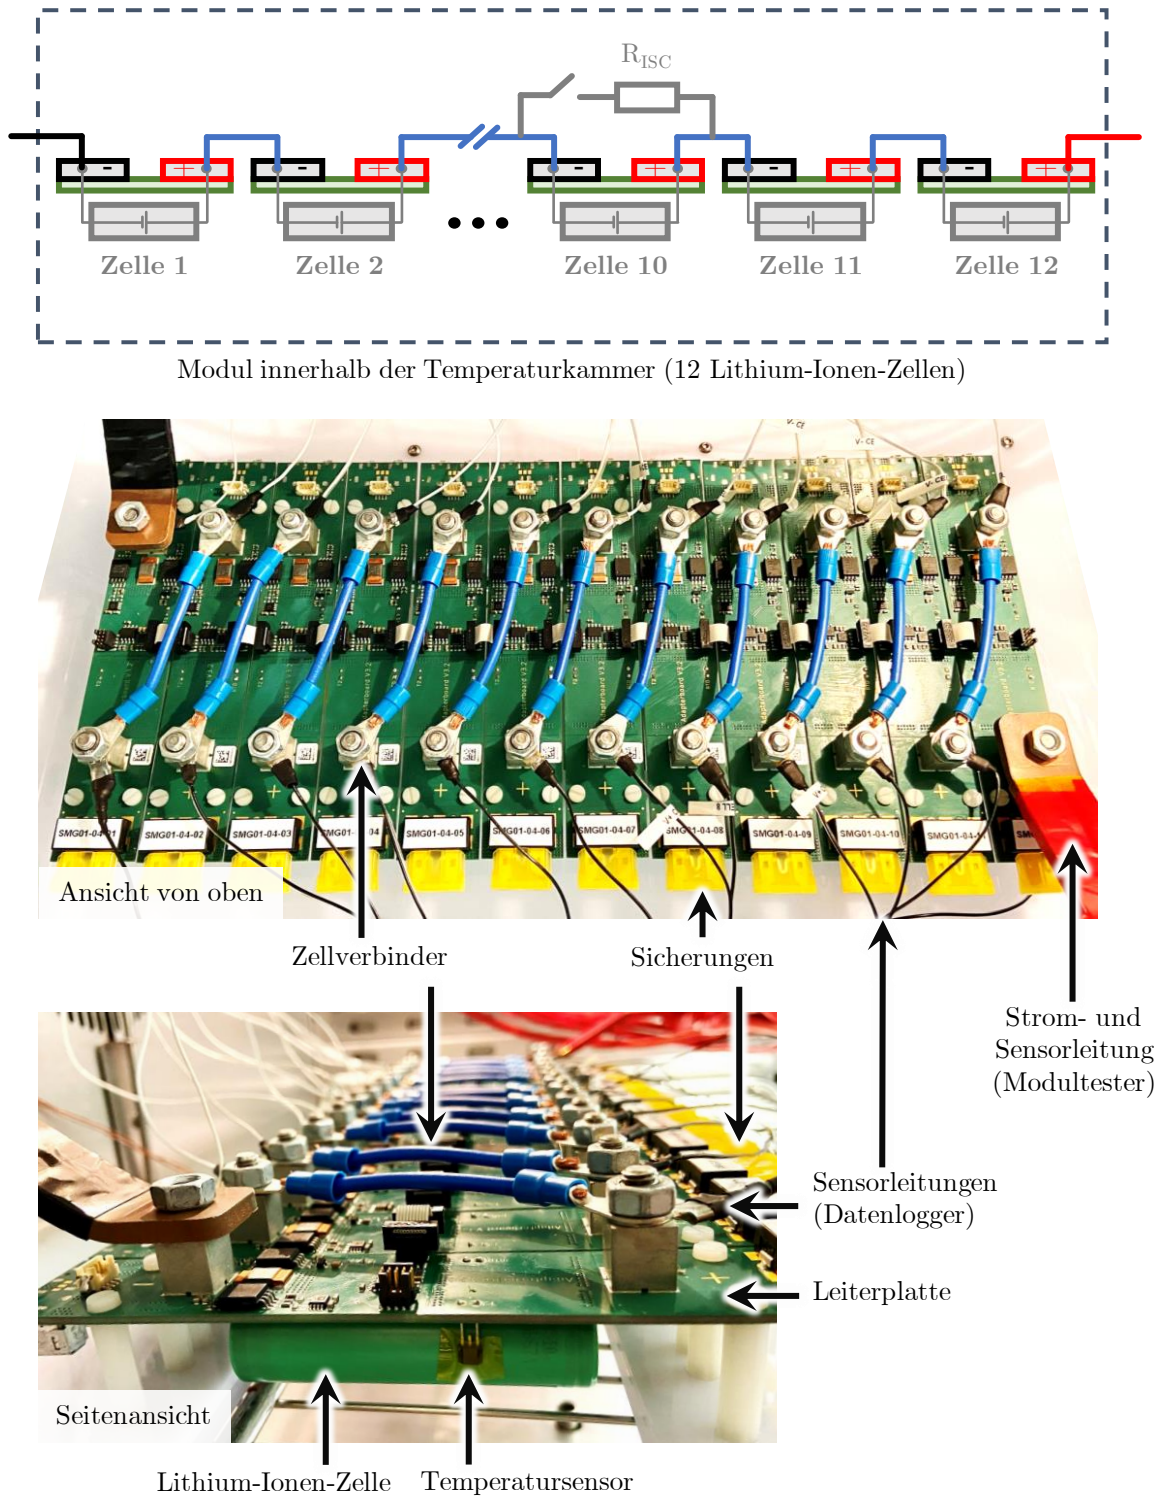


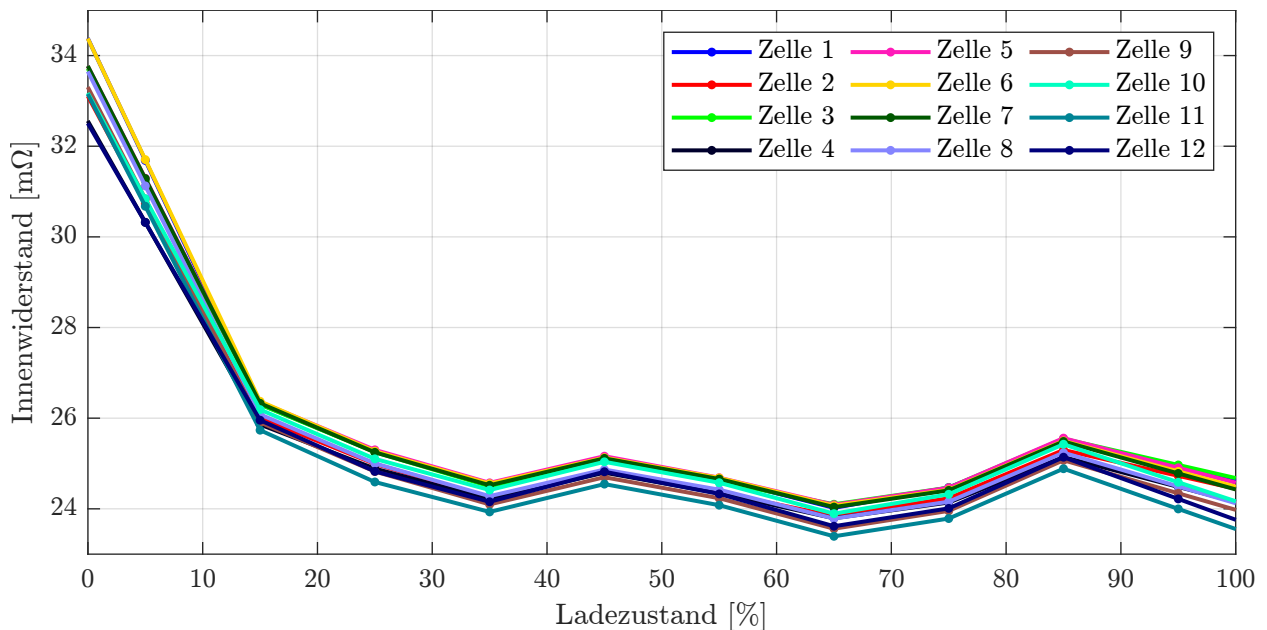
Abbildung 4.9: Schematischer und mechanischer Aufbau des SMG-Moduls.

maximalen Strömen von  $-4.73\text{ A}$  bis  $1.35\text{ A}$ . Nachdem die erste Zelle die untere Cut-Off-Spannung von  $2.5\text{ V}$  erreicht hat, folgt eine Schnellladung mit einer Rate von  $1.5\text{ C}$ , bis die erste Zelle eine Spannung von  $4\text{ V}$  erreicht hat. Nach einer weiteren Entladung mit AU- und



**Tabelle 4.2:** Ermittelte Zellkapazitäten der 12 SMG-Zellen (1 C-Entladung bei 25 °C).

Zelle	1	2	3	4	5	6
Kapazität [Ah]	2.326	2.324	2.320	2.321	2.321	2.323
Zelle	7	8	9	10	11	12
Kapazität [Ah]	2.329	2.330	2.319	2.320	2.331	2.326

**Abbildung 4.10:** Ermittelte Innenwiderstände (10 Hz) der SMG-Zellen bei 25 °C.


WLTP-basierten Stromprofilen folgt eine CCCV-Ladung mit einer Rate von 0.5 C, was einer Standard-Ladung der Zellen entspricht. Der gesamte Vorgang wird kontinuierlich wiederholt. Die Widerstände  $R_{\text{ISC}} \in \{10 \Omega, 100 \Omega, 1 \text{ k}\Omega, 10 \text{ k}\Omega\}$  emulieren in separaten Versuchen unterschiedlich weit fortgeschrittene Soft-ISCs.

Um die Parametervariationen der Zellen zu beziffern und um einen Zusammenhang zwischen den emulierten Kurzschlusswiderständen  $R_{\text{ISC}}$  und dem Innenwiderstand der Zellen herzustellen, werden zunächst die Kapazitäten und die Innenwiderstände bestimmt. Tabelle 4.2 zeigt die ermittelten Zellkapazitäten nach Konstantstrom-Entladung mit einer Stromrate von 1 C bei 25 °C. Im Vergleich zu den PAN-Zellen weisen die SMG-Zellen eine niedrigere Parametervariation auf. Die Kapazitätsunterschiede von 12 mAh entsprechen einer Variation von 0.5 % bezogen auf die Nennkapazität, während die PAN-Zellen eine Variation von 3 % zeigen. Die höhere Homogenität der SMG-Zellen ist auf das geringe zyklische Alter der Zellen zurückzuführen. Abbildung 4.10 zeigt die Gleichstrom-Widerstände (DC-Widerstände) nach 100 ms, die mit der Least-Squares-Methode während der dynamischen Entladung ermittelt wurden. Auch die Variationen der Innenwiderstände zwischen den Zellen sind über den gesamten SOC-Bereich homogen. In Übereinstimmung mit den identifizierten Parametern aus Abbil-

dung 3.7 steigt der Innenwiderstand im unteren SOC-Bereich an. Inhomogenitäten zwischen den Zellen lassen sich hauptsächlich als Offsets zwischen den Widerstandsprofilen beobachten. Die DC-Innenwiderstände bei 50 % SOC und 25 °C betragen  $24.619 \text{ m}\Omega \pm 0.306 \text{ m}\Omega$ . Selbst im Fall des am weitesten fortgeschrittenen ISCs  $R_{\text{ISC}} = 10 \Omega$  reduziert sich der Innenwiderstand durch den Fehler nur auf  $24.559 \text{ m}\Omega$ , was einer Änderung von  $0.060 \text{ m}\Omega$  entspricht. Diese Änderung liegt deutlich unter den Zellunterschieden und SOC- oder temperaturbedingten Variationen (siehe Abbildung 3.7). Dies erschwert die Erkennung des ISCs mit Methoden, die auf der Schätzung des Innenwiderstands basieren [147]. Wie von Zhang, Wei u. a. beschrieben, ist auch die Wärmegenerierung in diesem frühen Stadium gering [318]. Bei einer vollgeladenen Zelle mit einer Spannung von 4.2 V und dem kleinsten verwendeten Kurzschlusswiderstand von  $R_{\text{ISC}} = 10 \Omega$  (größte Wärmegenerierung) beträgt der zusätzliche Wärmeeintrag durch den ISC  $P_{\text{ISC}} = 1.764 \text{ W}$ . Die Leistung ist bei einem Innenwiderstand von  $24 \text{ m}\Omega$  vergleichbar mit der Wärmegenerierung, die bei einer Entladung der Zelle mit 8.6 A entsteht, was einem gewöhnlichen Betrieb entspricht. Auch wenn der Temperaturanstieg im Falle des  $10 \Omega$ -Widerstands messbar ist, ist er für die größeren Kurzschlusswiderstände vernachlässigbar. Die Wärmegenerierung verringert sich für die verwendeten Kurzschlusswiderstände jeweils um eine Größenordnung auf  $P_{\text{ISC}} = 0.176 \text{ W}$  ( $R_{\text{ISC}} = 100 \Omega$ ),  $P_{\text{ISC}} = 0.018 \text{ W}$  ( $R_{\text{ISC}} = 1 \text{ k}\Omega$ ), beziehungsweise  $P_{\text{ISC}} = 0.002 \text{ W}$  ( $R_{\text{ISC}} = 10 \text{ k}\Omega$ ).

Abbildung 4.11 zeigt die Abweichungen der Einzelzellspannungen vom Median aller 12 Zellen 21 h vor und 21 h nach Auftreten der ISCs mit  $R_{\text{ISC}} \in \{10 \Omega, 100 \Omega, 1 \text{ k}\Omega, 10 \text{ k}\Omega\}$ . Der Zeitpunkt  $t = 0 \text{ h}$ , zu dem der ISC emuliert wird, ist durch eine schwarze gestrichelte Linie markiert. Die 11 fehlerfreien Zellen sind schwarz dargestellt und die fehlerhafte Zelle ist rot markiert. Zur Vergleichbarkeit der Messungen besitzen alle Diagramme in Abbildung 4.11 die gleichen Skalen. Aufgrund der Parametervariationen der Zellen sind bereits im fehlerfreien Zeitraum Abweichungen von bis zu 50 mV vom Median zu beobachten. Wie bei der PAN-Zelle treten diese charakteristischen Peaks im niedrigen SOC-Bereich auf. Der große Gradient der Ruhespannungskurve verstärkt die Abweichung im niedrigen SOC-Bereich zusätzlich (siehe Abbildung 3.7,  $E_m$ ). Nach der Emulation des ISCs nimmt die Abweichung von der Medianspannung für die betroffene fehlerhafte Zelle zu. Während für den  $10 \Omega$ -Kurzschluss ein schneller Anstieg der Spannungsdifferenz zu beobachten ist, ist er im  $10 \text{ k}\Omega$ -Fall kaum erkennbar. Besonders in der frühen Phase verschwinden die durch den ISC verursachten Spannungsunterschiede in den üblichen Abweichungen aufgrund von nicht-optimalem Balancing und Parameterunterschieden. Deshalb ist es herausfordernd, insbesondere hochohmige Kurzschlüsse in einer frühen Phase zuverlässig zu detektieren.

Abbildung 4.12 zeigt die Abweichung der Spannungsverläufe zwischen jeweils zwei SMG-Zellen während des Trainings, exemplarisch für die beiden Fälle  $R_{\text{ISC}} = 10 \Omega$  und  $R_{\text{ISC}} = 10 \text{ k}\Omega$ . Wie im PAN-Modul lässt sich für jede der Zellen eine weitere Zelle identifizieren, deren gemessene Spannung einen RMSE von weniger als 3 mV aufweist. Zudem besitzen in beiden Fällen zwei beliebig ausgewählte Zellen einen Spannungs-RMSE von weniger als 14 mV. Diese




**Abbildung 4.11:** Spannungsdifferenzen der SMG-Zellen bezogen auf die Median-Zelle für die Fälle  $R_{\text{ISC}} \in \{10\Omega, 100\Omega, 1\text{k}\Omega, 10\text{k}\Omega\}$ .

Form der physikalischen Redundanz ist vergleichbar mit einer analytischen Redundanz, die ein Modell mit ähnlicher Güte erzielt. Der gesamte Modellierungs- und Berechnungsaufwand des Modells entfällt im Falle der physikalischen Redundanz jedoch.

#### 4.2.4 Messdaten von realen Straßenfahrten

Neben den am Prüfstand aufgezeichneten Daten verwendet die Arbeit zur Validierung der Methoden auch Messdaten aus dem Fahrzeug. Die Daten wurden auf dem Fahrzeugbus eines PHEV-Prototyps mitgeloggt und umfassen einen neuen (100% SOH) und einen gealterten




**Abbildung 4.12:** Box-Plots des RMSEs aller 12 SMG-Zellen untereinander während des Trainings.

(95 % SOH) Batteriepack. Das Batteriesystem besteht aus 104 48 Ah-Zellen, die seriell in einer 104s1p-Topologie verschaltet sind. Die Abtastrate der Einzelzellspannungsmessungen beträgt wie bei den Prüfstandsmessungen 10 Hz bei einer Auflösung von 1 mV.


Wie in Abbildung 4.13 (oben) zu erkennen, entlädt der dynamische Fahrbetrieb den geladenen Batteriespeicher des Hybridfahrzeugs zunächst (*Charge-Depleting-Modus*). Nach dem anschließenden *Charge-Sustaining-Betrieb*, bei dem der Ladezustand weitgehend konstant bleibt, lädt die Fahrzeugbatterie. In den Daten sind Pausenzeiträume zu beobachten, in denen auch die Messung pausiert. Die dynamische Entladung erfolgt mit einer Peak-Entladeleistung von  $-115 \text{ kW}$  und einer Peak-Rekuperationsleistung von  $60 \text{ kW}$ , woraus, abhängig von der Batteriespannung, maximale Ströme von  $-330 \text{ A}$  bis  $155 \text{ A}$  resultieren. Die Ladung erfolgt mit einer konstanten Leistung von  $6 \text{ kW}$ , woraus Zellströme von etwa  $14 \text{ A}$  bis  $17 \text{ A}$  folgen. Der SOC-Bereich, in dem der Batteriepack während der Messung aus Abbildung 4.13 betrieben wird, reicht von  $16 \%$  bis  $95 \%$ .

In den Messdaten simuliert ein Kurzschlusswiderstand von  $R_{ISC} = 10 \Omega$  beziehungsweise  $R_{ISC} = 100 \Omega$  zum Zeitpunkt  $t = 0 \text{ h}$  einen ISC modellbasiert. Wie für die am Prüfstand aufgezeichneten Messdaten mit den PAN- und SMG-Zellen zeigt Abbildung 4.13 (Mitte, unten) für alle 104 Zellen die Abweichung der Einzelzellspannungen von der Medianspannung. Im Unterschied zu den Prüfstandsmessungen sind die Peaks in den Abweichungen von der Medianspannung während den fehlerfreien Messungen nicht so stark ausgeprägt. Dies ist auf den SOC-Bereich zurückzuführen, in dem der Batteriepack betrieben wurde. Wie in Abbildung 3.6,  $E_m$  an der Ruhespannung zu erkennen ist, erreichen die Zellen den Bereich, in dem die Kennlinie eine große Steigung aufweist, nur für kleinere SOC-Werte. Ein minimaler SOC von  $16 \%$  entspräche bei den PAN-Zellen in Abbildung 3.6,  $E_m$  einem DOD von  $-21 \text{ Ah}$ , bezogen auf die Nennkapazität von  $25 \text{ Ah}$ .

Zudem besitzen die PHEV-Zellen eine hohe Homogenität, wie auch Abbildung 4.14 zeigt.




**Abbildung 4.13:** Einzelzellspannungen (oben) und Zellspannungsdifferenzen (Mitte, unten) des PHEV-Batteriepacks (95% SOH) bezogen auf die Median-Zelle für die Fälle  $R_{\text{ISC}} = 10\ \Omega$  und  $R_{\text{ISC}} = 100\ \Omega$ .



**Abbildung 4.14:** Box-Plot des RMSEs aller 104 PHEV-Zellen untereinander während des Trainings.

Obwohl der Batteriepack, im Unterschied zu den Prüfstandsmodulen, 104 Zellen besitzt, beträgt der RMSE der Spannungsverläufe zweier beliebiger Zellen weniger als 4 mV. Gemessen an der Genauigkeit aufwändiger Modelle (siehe Tabelle 3.6), verspricht bereits dieser schlechteste Fall eine hohe Sensitivität für die Fehlerdiagnose. Für die Mehrheit der 104 Zellen




**Abbildung 4.15:** Zellkapazitäten der 432 Zellen im Modell (3% Parametervariation).

existiert jedoch darüber hinaus jeweils eine ähnliche Zelle, deren Spannungsverlauf einen kleineren RMSE als 0.5 mV besitzt. In allen Fällen lässt sich eine Zelle finden, die über den gesamten SOC-Bereich einen Spannungsverlauf mit einem geringeren RMSE als 1.6 mV aufweist, was in der Größenordnung der Sensorauflösung liegt. Dies ist neben der höheren Homogenität auch in der größeren Anzahl an Zellen begründet.

#### 4.2.5 Simulationsdaten aus dem Batteriepackmodell


Als weitere Datengrundlage dienen mit dem Modell aus Kapitel 3 simulierte Daten, nachfolgend als MDL-Daten bezeichnet. Der gewählte Batteriepack verfügt über 432 25 Ah-Zellen in einer 108s4p-Topologie. Ein Kurzschlusswiderstand  $R_{\text{ISC}}$  simuliert, wie in Abbildung 3.4c dargestellt, den ISC. Ausgehend vom resultierenden Kurzschlussstrom  $i_{\text{ISC}}$  ermöglicht das Modell zudem, die vom ISC verursachte Wärmegenerierung zu berücksichtigen. Der zusätzliche Wärmeeintrag in den Zellwickel beträgt  $P_{\text{ISC}} = R_{\text{ISC}} i_{\text{ISC}}^2$  und führt bei weiter fortgeschrittenen ISCs auch zu einem Temperaturanstieg benachbarter Zellen (siehe Abbildung A.6).

Um eine Vergleichbarkeit mit den Prüfstands- und Straßenmessungen herzustellen, beträgt die Auflösung der simulierten Sensorik 1 mV bei einer Abtastrate von 10 Hz. Die Simulation verwendet die für die PAN-Zellen identifizierten Parameter. Abbildung 4.15 zeigt die Kapazitäten aller 432 Zellen. Die Zellen haben eine mittlere Kapazität von 23 Ah, was einem SOH von 92% bezogen auf die Nennkapazität von 25 Ah entspricht. Der Parameter-Variationsvektor  $\Delta_{\text{Q}}(\sigma_{\text{Q}})$  nach Gleichung (3.144) besitzt die Standardabweichung  $\sigma_{\text{Q}} = 3\%$ . Wie die ermittelten Widerstände der PAN- und SMG-Zellen in den Abbildungen 4.3 und 4.10 zeigen, äußert sich die Parametervariation in den Innenwiderständen vor allem durch eine Verschiebung der Kennlinien. Dies bestätigt den Ansatz, auch die Wertetabellen des Modells mit einem Parameter-Variationsvektor zu skalieren. Abbildung 4.16 zeigt die SOC- und temperaturabhängigen Wertetabellen für den Innenwiderstand zu allen 432 Zellen. Die Widerstandswerte basieren auf den identifizierten Innenwiderständen der PAN-Zelle (siehe Abbildung 3.6) mit einem Variationsvektor, der eine Standardabweichung von  $\sigma_{\text{R}_0} = 5\%$  besitzt. Die Farben entsprechen den Temperaturen von 15 °C bis 45 °C; die Farbtöne repräsentieren die Zellnummer.



**Abbildung 4.16:** Innenwiderstände der 432 Zellen im Modell (5% Parametervariation).

Abbildung 4.17 (oben) zeigt die resultierenden Einzelzellspannungen des Modells. Als Anregungsstrom für die dynamische Entladung des Batteriepacks dient ein Stromprofil auf Basis des WLTP-Fahrzyklus. Sobald die erste Zelle die untere Cut-Off-Spannung von 3V erreicht hat, folgt eine Konstantstromladung mit 25 A. Hat die erste Zelle die obere Cut-Off-Spannung von 4.1 V erreicht, beginnt eine erneute dynamische Entladung. Zum Zeitpunkt  $t = 0$  h simuliert ein  $10\ \Omega$ -Widerstand einen ISC in Zelle 10. Abbildung 4.17 (unten) zeigt die Abweichung der Einzelzellspannungen von der Medianspannung. Trotz der mit dem PAN-Modul aus Abschnitt 4.2.2 vergleichbaren Parametervariationen, besitzen die Peaks der Spannungsdifferenzen eine Amplitude von über 300 mV. Dies ist auf die größere Anzahl an Zellen zurückzuführen. Aufgrund der 36-fachen Zellanzahl steigt auch die Wahrscheinlichkeit für größere Parameterunterschiede zwischen der stärksten und der schwächsten Zelle. Da im vorliegenden Batteriepack je vier Zellen parallelgeschaltet sind, beeinflusst der ISC in Zelle 10 auch die benachbarten Zellen 9, 11 und 12. Während die ISC-bedingte Wärmegenerierung nur in Zelle 10 erfolgt, entlädt die fehlerhafte Zelle die benachbarten Zellen aufgrund ihrer elektrischen Verbindung ebenfalls. Der etwas geringere Einfluss des ISCs auf die parallelen Zellen verglichen mit Zelle 10 resultiert daraus, dass das Modell auch Kontakt- und Stromschienenwiderstände berücksichtigt. Dadurch, dass die Nachbarzellen Zelle 10 speisen, ist die resultierende Spannungsänderung durch den  $10\ \Omega$ -Kurzschluss mit der einer  $4 \cdot 25\ \text{Ah} = 100\ \text{Ah}$ -Zelle vergleichbar. Nimmt man umgekehrt eine lineare Ruhespannungskennlinie an, so ist der Einfluss des simulierten ISCs mit einem  $40\ \Omega$ -ISC bei einer 25 Ah-Zelle vergleichbar.



**Abbildung 4.17:** Einzelzellspannungen (oben) und Zellspannungsdifferenzen (unten) des Batteriepack-Modells (92 % SOH) bezogen auf die Median-Zelle für den Fall  $R_{ISC} = 10 \Omega$ .

#### 4.2.6 Übersicht Datengrundlage

Zusammenfassend vergleicht Tabelle 4.3 die Datengrundlage unter verschiedenen Gesichtspunkten. Während der Prüfstand jeweils ein seriell verschaltetes Modul mit 12 Zellen testet, stammen die experimentellen PHEV-Daten von einem vollständigen Batteriesystem mit 104 seriellen Zellen. Das Modell bietet die Möglichkeit beliebig auf Modul- oder Systemebene mit einer freien Anzahl an Zellen zu testen. Die Parallelschaltung des gewählten Batteriepacks, bestehend aus 432 Zellen, lässt zudem eine Validierung im Parallelverbund zu. Die Datengrundlage umfasst experimentelle Daten zu zylindrischen, prismatischen und Pouch-Zellen, die Modellparametrierung erfolgte mit den zylindrischen SMG- und den prismatischen PAN-Zellen. Das Zellformat ist jedoch vor allem für mechanische und thermische Untersuchungen von Bedeutung und spielt für die elektrischen Eigenschaften eine untergeordnete Rolle.

Analog zu den Fahrzeugbusdaten wurden für den Prüfstand und das Modell Abstraten der Sensorik von 10 Hz gewählt. Die Genauigkeit der Prüfstandssensorik ergibt sich aus einer 16-Bit-Analog/Digital-Wandlung des Hioki-Datenloggers und dem gewählten Messbereich von  $-15 \text{ V}$  bis  $15 \text{ V}$ . Die Genauigkeit von  $0.5 \text{ mV}$  liegt in der Größenordnung der gemessenen Fahrzeugbusdaten. Ein simulierter Sensor reduziert die Messgenauigkeit des Batteriemodells



**Tabelle 4.3:** Übersicht und Vergleich der Datengrundlage.

	<b>SMG</b>	<b>PAN</b>	<b>PHEV</b>	<b>MDL</b>
<b>Ebene</b>	Modul	Modul	System	System
<b>Zellanzahl</b>	12 Zellen	12 Zellen	104 Zellen	432 Zellen
<b>Konfiguration</b>	12s1p	12s1p	104s1p	108s4p
<b>Zellkapazität</b>	2.5 Ah	25 Ah	48 Ah	25 Ah
<b>Format</b>	zylindrisch (18650)	prismatisch	Pouch	prismatisch
<b>Abtastrate</b>	10 Hz	10 Hz	10 Hz	10 Hz
<b>Auflösung</b>	0.5 mV	0.5 mV	1 mV	1 mV
<b>Datenart</b>	Experimentell	Experimentell	Experimentell	Simulativ
<b>Anregung</b>	Beliebig	Beliebig	Straßenfahrt	Beliebig
<b>Alterung</b>	Neu	Gealtert	Neu, Gealtert	Neu, Gealtert, Alterungsverlauf
<b>ISC</b>	Emulation	Emulation	Simulation	Simulation mit Temperatur

auf die Genauigkeit der Busdaten von 1 mV. Da die Anforderungen der entwickelten Methoden an die Sensorik gering sind, werden diese in allen Fällen erreicht.

Die Vorteile des Prüfstands gegenüber der realen Straßenfahrt liegen darin, dass die Anregung frei wählbar ist. Dies ermöglicht auch eine Validierung über den kompletten SOC-Bereich. Zudem emuliert ein Widerstand den ISC experimentell, was dem elektrischen Verhalten sehr nahekommt. Das neue SMG-Modul und das gealterte PAN-Modul decken darüber hinaus verschiedene Alterungszustände ab. Die Zellanzahl ist jedoch in den vorliegenden Daten auf 12 begrenzt.

Auch wenn serielle Batteriezellen elektrisch nicht interagieren, ist eine Validierung auf Systemebene ein Mehrwert, beispielsweise um die Performanz der Algorithmen abzuschätzen. Die experimentellen PHEV-Daten bieten eine Möglichkeit dazu. Zudem basiert das Fahrprofil auf einer realen Straßenfahrt und erfordert einen Umgang mit Messausfällen oder -pausen. Da das Fahrprofil jedoch nicht direkt beeinflussbar ist, fehlen beispielsweise Messdaten im niedrigen Ladezustandsbereich unter 16 % SOC. Dadurch, dass Messdaten zu einer neuen und einer gealterten PHEV-Batterie vorliegen, lassen sich die Methoden auch in verschiedenen Lebenszyklen validieren. Die ISC-Simulation erfolgt jedoch nur simulativ. Auch wenn das elektrische Verhalten damit weitgehend abgebildet wird, werden die Wärmegenerierung und

der resultierende Temperaturanstieg dabei nicht berücksichtigt.

Die Möglichkeit diese ISC-Effekte zu berücksichtigen, bietet hingegen das Modell. Sowohl die Wärmegenerierung der fehlerhaften Zelle also auch der Temperaturanstieg der benachbarten Zellen ist berücksichtigt. Zudem lässt sich, wie bei den experimentellen Daten, der komplette SOC-Bereich validieren. Ein Balancing sowie gezieltes Laden und Entladen der Zellen entfällt, da jeder Betriebspunkt initial gesetzt werden kann. Neben einem neuen und gealterten Batteriesystem ist mit dem Modell auch der Alterungsverlauf abbildbar, der in experimentellen Versuchen sehr lange Zeiträume erfordert. Ein weiterer Vorteil des Modells liegt im Zugriff auf die internen Zellgrößen. Wie in Abbildung 3.13 gezeigt, sind Parameter und Zustände wie die Widerstände, Kapazitäten und SOCs jeder Zelle bekannt. Da jedoch nicht alle untergeordneten, reale Zelleffekte berücksichtigt sind und die Sensorik ebenfalls nur simulativ nachgebildet ist, erweist sich eine Validierung mit experimentellen Daten stets als sinnvoll.

Zusammenfassend hat jede Datengrundlage, aufgrund der diskutierten Vor- und Nachteile, ihre Berechtigung als Validierung der Methoden herangezogen zu werden. Die Gesamtheit der vier Datenquellen ermöglicht eine solide und plausible Validierung der Algorithmen.

## 4.3 Vorverarbeitung der Daten

Während die Messdaten, wie in Tabelle 4.3 zusammengefasst, mit einer Rate von 10 Hz erfasst werden, arbeiten die entwickelten Detektionsalgorithmen mit einer Berechnungsfrequenz von 0.1 Hz. Den Eingang bilden deshalb immer über 100 Werte gemittelte Daten. 2/3 der Daten vor Auftreten des ISCs dienen als Trainingsdaten, das verbleibende Drittel der Daten dient zum Test im fehlerfreien Fall. Basierend auf gemessenen Zellspannungsvektoren, geschrieben als  $\mathbf{v}_\tau \in \mathbb{R}^m$ , für  $m$  Zellen zum Zeitpunkt  $\tau \in [1, N]$  und  $c \in [1, m]$ , erfolgt das Training offline und der Test online. Die Variable  $\tau$  bezeichnet einen Zeitpunkt während des Trainings, die Variable  $t$  einen Zeitpunkt während des Tests. Das Element der  $\tau$ -ten Zeile und  $c$ -ten Spalte der Matrix  $\mathbf{V} = [\mathbf{v}_1, \dots, \mathbf{v}_\tau, \dots, \mathbf{v}_N]^T \in \mathbb{R}^{N \times m}$  wird als  $v_{\tau c}$  geschrieben.

### 4.3.1 Robuste Studentisierung

Die Datenvorverarbeitung berechnet zunächst den Sample-weisen Median

$$\bar{v}_\tau^{\text{med}} = \frac{\tilde{v}_\tau \left\lfloor \frac{m+1}{2} \right\rfloor + \tilde{v}_\tau \left\lceil \frac{m+1}{2} \right\rceil}{2}, \quad (4.150)$$

wobei  $\tilde{\mathbf{v}}_\tau = [\tilde{v}_{\tau 1}, \dots, \tilde{v}_{\tau c}, \dots, \tilde{v}_{\tau m}] \in \mathbb{R}^m$  die über die Dimensionen  $\tilde{v}_{\tau 1} \leq \dots \leq \tilde{v}_{\tau c} \leq \dots \leq \tilde{v}_{\tau m}$  aufsteigend sortierte Version von  $\mathbf{v}_\tau \in \mathbb{R}^m$  ist. Die Tilde kennzeichnet an dieser Stelle sortierte Werte. Die Klammern  $\lfloor \cdot \rfloor$  bezeichnen die Abrundung (*Floor-Operator*),  $\lceil \cdot \rceil$  die Aufrundung (*Ceil-Operator*). Die Berechnung des Medians hat gegenüber dem Mittelwert den Vorteil,

dass sie robust gegenüber Ausreißern ist, da der Einfluss von Extremwerten begrenzt ist [71, 321]. Dies ist vor allem in Anwesenheit von Fehlern wichtig, um eine Verschiebung des Zentrums der Daten zu vermeiden. Ausgehend vom Median  $\bar{v}_\tau^{\text{med}}$  lässt sich eine robuste Form der Standardabweichung

$$s_\tau^{\text{med}} = \sqrt{\frac{1}{m_z - 1} \sum_{c=1}^{m_z} (\tilde{v}_{\tau c} - \bar{v}_\tau^{\text{med}})^2} \quad (4.151)$$

mit einer Teilmenge von  $m_z \leq m$  Signalen mit dem kleinsten z-Score berechnen. Die Wahl der Teilmenge erfolgt gemäß  $m_z = \lceil \frac{5}{6}m \rceil$ , woraus für die Modulversuche  $m_z = 10$ , für das PHEV-System  $m_z = 87$  und  $m_z = 360$  für das Batteriemodell resultiert. Ein alternatives Maß für die robuste Approximation der Streuung wäre die Median-Absolute-Deviation, die dem Median der betragsmäßigen Abweichung vom Median entspricht [5]. Die robuste Studentisierung, im Folgenden als Outlier-Robust-Sample-Studentization (ORSS) bezeichnet, berechnet sich gemäß

$$\mathbf{x}_\tau = \frac{\mathbf{v}_\tau - \bar{v}_\tau^{\text{med}} \mathbf{1}_m}{s_\tau^{\text{med}}} \in \mathbb{R}^m, \quad (4.152)$$

sodass die Datenmatrix  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_\tau, \dots, \mathbf{x}_N]^T \in \mathbb{R}^{N \times m}$  folgt. Die ORSS jedes Testsamples  $\mathbf{v}_t$  erfolgt analog, woraus der Vektor  $\mathbf{x}_t$  resultiert.

Im Anschluss an die robuste Studentisierung erfolgt eine Zentrierung der Spalten  $\boldsymbol{\xi}_c = [x_{1c}, \dots, x_{\tau c}, \dots, x_{Nc}]^T \in \mathbb{R}^N$  der Matrix  $\mathbf{X}$ , wie sie für PCA-basierte Methoden notwendig ist [1]. Ausgehend von den Trainingsdaten wird eine dimensionsweise Zentrierung der Daten mit dem Mittelwert

$$\bar{\xi}_c^{\text{train}} = \frac{1}{N} \sum_{\tau=1}^N x_{\tau c} \quad (4.153)$$

und der Standardabweichung


$$s_c^{\text{train}} = \sqrt{\frac{1}{N-1} \sum_{\tau=1}^N (x_{\tau c} - \bar{\xi}_c^{\text{train}})^2} \quad (4.154)$$

durchgeführt. Die Zentrierung von  $\boldsymbol{\xi}_c$  erfolgt nach

$$\boldsymbol{\zeta}_c = \frac{\boldsymbol{\xi}_c - \bar{\xi}_c^{\text{train}} \mathbf{1}_N}{s_c^{\text{train}}} \in \mathbb{R}^N. \quad (4.155)$$

Das Ergebnis der Datenvorverarbeitung ist eine Datenmatrix

$$\mathbf{Z} = [\boldsymbol{\zeta}_1 \dots \boldsymbol{\zeta}_c \dots \boldsymbol{\zeta}_m] = \begin{bmatrix} z_{11} & \dots & z_{1c} & \dots & z_{1m} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ z_{\tau 1} & \dots & z_{\tau c} & \dots & z_{\tau m} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ z_{N1} & \dots & z_{Nc} & \dots & z_{Nm} \end{bmatrix} \in \mathbb{R}^{N \times m} \quad (4.156)$$




**Abbildung 4.18:** Eingangsdaten, basierend auf den Zellspannungen des SMG-Moduls nach Vorverarbeitung mit der ORSS für den Fall  $R_{\text{ISC}} = 10 \text{ k}\Omega$ .

mit Zeilen  $\mathbf{z}_\tau \in \mathbb{R}^m$ . Eine analoge Studentisierung der Testdaten  $\mathbf{x}_t$  mit dem Mittelwert  $\bar{\xi}_c^{\text{train}}$  und der Standardabweichung  $s_c^{\text{train}}$  liefert  $\mathbf{z}_t \in \mathbb{R}^m$ .

### 4.3.2 Datengrundlage nach der Studentisierung

Zwei Datensätze demonstrieren exemplarisch die resultierenden Eingangsdaten nach der Vorverarbeitung. Abbildung 4.18 zeigt die Ergebnisse für das neue SMG-Modul im Falle des  $10 \text{ k}\Omega$ -ISCs und Abbildung 4.19 zeigt die vorverarbeiteten Spannungsmessungen für das gealterte PAN-Modul im Falle des  $100 \Omega$ -ISCs. Die 66 Teildiagramme der beiden Abbildungen zeigen zweidimensionale Projektionen der Eingangsdatenmatrix  $\mathbf{Z}$  jeweils in Richtung der  $m = 12$  Feature-Vektoren  $\zeta_c \in \mathbb{R}^N$ . Blaue Punkte kennzeichnen die vorverarbeiteten Messungen während des Trainings, rote Punkte entsprechen den Testdaten. Die Testdaten umfassen 1/3 der fehlerfreien Daten vor Auftreten des ISCs sowie den gesamten Zeitraum nach Auftreten des ISCs. Da die Zellen des SMG-Moduls geringe Parametervariationen zeigen und selbst im niedrigen Ladezustandsbereich maximale Abweichungen von unter  $50 \text{ mV}$  besitzen, dominiert das Sensorrauschen in den vorverarbeiteten Daten. Die Verteilungen im Training und im Test sind weitgehend identisch. Nach Emulation des ISCs in Zelle 10 zeigt sich jedoch



**Abbildung 4.19:** Eingangsdaten, basierend auf den Zellspannungen des PAN-Moduls nach Vorverarbeitung mit der ORSS für den Fall  $R_{ISC} = 100 \Omega$ .

eine Änderung der Verteilung entlang der  $\zeta_{10}$ -Achse. Im Unterschied zum SMG-Modul zeigen die in Abbildung 4.19 dargestellten Einträge der  $\mathbf{Z}$ -Matrix systematische Variationen. Die nichtlinearen Beziehungen zwischen den Variablen  $\zeta_c \in \mathbb{R}^N$  dominieren das von den Sensoren verursachte Rauschen. Die systematischen Variationen sind auf die inhomogenen Parameter der Zellen zurückzuführen. Unterschiede in der Zellkapazität, dem Innenwiderstand, den Polarisationsspannungen oder der OCV aber auch schlechtes Balancieren führen zu einer nichtlinearen, nicht-Gaußschen Verteilung der Zellspannungsdifferenzen. Die Parametervariationen gealterter Batteriepacks erfordern deshalb von den entwickelten Algorithmen einen Umgang mit den genannten Effekten.

## 4.4 Lineares Zellmonitoring

Wie in Abschnitt 2.4.2 vorgestellt, transformiert die PCA Daten aus einem multivariaten Raum in einen Unterraum, der die Hauptinformationen mit einer reduzierten Dimension enthält [88]. Das Monitoring zur Fehlerdiagnose setzt sich aus zwei Schritten zusammen. Der erste Schritt beinhaltet das Training des Datenmodells (Abschnitt 4.4.1). Der zwei-

te Schritt umfasst die Auswertung der Testdaten mit Hilfe von Statistiken, die auf dem trainierten Modell basieren (Abschnitt 4.4.2) [27]. Dieser Ansatz zur Merkmalsextraktion aus hochdimensionalen Daten ermöglicht auch die Überwachung komplexer Prozesse, ohne ein physikalisches Modell [58, 315]. Abschnitt 4.4.3 analysiert die Beiträge aller Variablen zu den Kontrollstatistiken, um Fehler zu isolieren. Da sich die Betriebsbedingungen und Zellparameter in Batteriesystemen kontinuierlich ändern, stellt Abschnitt 4.4.4 Verfahren zur Anpassung des gelernten Datenmodells vor. Abschnitt 4.4.5 untersucht den Einfluss unterschiedlicher Anregungsprofile im Training und Test.

#### 4.4.1 Training des Datenmodells

Um eine PCA-basierte Überwachung durchzuführen, wird die Kovarianzmatrix

$$\mathbf{C} = \frac{1}{N-1} \sum_{\tau=1}^N \mathbf{z}_{\tau} \mathbf{z}_{\tau}^T = \frac{1}{N-1} \mathbf{Z}^T \mathbf{Z} \in \mathbb{R}^{m \times m} \quad (4.157)$$

anhand der Datenmatrix  $\mathbf{Z}$  approximiert [88, 225, 266]. Mit den Einzelzellspannungen als Eingangsdaten bestimmt die Anzahl der Zellen im Batteriesystem die Dimension der Kovarianzmatrix. Eine SVD von  $\mathbf{C}$  liefert

$$\mathbf{C} = \mathbf{U} \mathbf{\Sigma} \mathbf{V}^*, \quad (4.158)$$

mit  $\mathbf{U}, \mathbf{\Sigma}, \mathbf{V} \in \mathbb{R}^{m \times m}$ . Da die Kovarianzmatrix  $\mathbf{C}$  symmetrisch und positiv definit ist, impliziert sie  $\mathbf{P} := \mathbf{U} = \mathbf{V}^*$  und  $\mathbf{\Lambda} = \mathbf{\Sigma}$ , so dass

$$\mathbf{C} = \mathbf{P} \mathbf{\Lambda} \mathbf{P}^T \quad (4.159)$$

resultiert. Die Spalten von  $\mathbf{P} = [\mathbf{p}_1 \dots \mathbf{p}_m] \in \mathbb{R}^{m \times m}$  entsprechen den Eigenvektoren von  $\mathbf{C}$ , sind orthogonal, haben die Länge  $\|\mathbf{p}_j\| = 1$  und bilden somit eine Orthonormalbasis des von  $\mathbf{C}$  aufgespannten Raums. Wenn die Kovarianzmatrix vollen Rang  $m$  hat, was bei  $N \gg m$  und Daten, die auf gemessenen, verrauschten Signalen basieren, üblicherweise der Fall ist, dann ist  $\text{span}\{\mathbf{C}\} \equiv \text{span}\{\mathbf{P}\}$ . Die Matrix  $\mathbf{\Lambda}$  ist eine Diagonalmatrix

$$\mathbf{\Lambda} = \text{diag}(\lambda_1 \dots \lambda_m) \in \mathbb{R}^{m \times m} \quad (4.160)$$

mit den Singulärwerten entsprechend den absteigend geordneten Eigenwerten  $\lambda_1 \geq \dots \geq \lambda_m \geq 0$  der Kovarianzmatrix  $\mathbf{C}$ :

$$\mathbf{C} \mathbf{p}_j = \lambda_j \mathbf{p}_j. \quad (4.161)$$

Die Matrix  $\mathbf{P}$  kann also als Rotationsmatrix interpretiert werden, die den von  $\mathbf{C}$  aufgespannten Raum in Richtung der größten Datenvarianz rotiert. Die Eigenvektoren  $\lambda_i$  geben die Varianz

der Daten entlang der Basis im neuen Raum an. Der Raum  $\tilde{\mathbf{P}} = \mathbf{P}\mathbf{\Lambda}$  entspricht einer gedrehten und skalierten Version des ursprünglichen Raumes basierend auf den Trainingsdaten. Der von

$$\mathbf{P} = [\mathbf{p}_1 \dots \mathbf{p}_\beta \mathbf{p}_{\beta+1} \dots \mathbf{p}_m] = [\mathbf{P}_{\text{pc}} \mathbf{P}_{\text{res}}] \quad (4.162)$$

aufgespannte Raum wird in zwei orthogonale Unterräume mit  $\mathbf{P}_{\text{pc}} \in \mathbb{R}^{m \times \beta}$  und  $\mathbf{P}_{\text{res}} \in \mathbb{R}^{m \times (m-\beta)}$  zerlegt. Analog dazu erfolgt eine Aufteilung von

$$\mathbf{\Lambda} = \text{diag}(\lambda_1 \dots \lambda_\beta \lambda_{\beta+1} \dots \lambda) = \begin{bmatrix} \mathbf{\Lambda}_{\text{pc}} & \mathbf{0} \\ \mathbf{0} & \mathbf{\Lambda}_{\text{res}} \end{bmatrix} \in \mathbb{R}^{m \times m} \quad (4.163)$$

in  $\mathbf{\Lambda}_{\text{pc}} \in \mathbb{R}^{\beta \times \beta}$  und  $\mathbf{\Lambda}_{\text{res}} \in \mathbb{R}^{(m-\beta) \times (m-\beta)}$ , sodass eine Zerlegung

$$\mathbf{C} = \begin{bmatrix} \mathbf{P}_{\text{pc}} & \mathbf{P}_{\text{res}} \end{bmatrix} \begin{bmatrix} \mathbf{\Lambda}_{\text{pc}} & \mathbf{0} \\ \mathbf{0} & \mathbf{\Lambda}_{\text{res}} \end{bmatrix} \begin{bmatrix} \mathbf{P}_{\text{pc}}^T \\ \mathbf{P}_{\text{res}}^T \end{bmatrix} \quad (4.164)$$

resultiert. Der Unterraum  $\mathbf{P}_{\text{pc}}$  wird als Hauptunterraum bezeichnet und enthält die Hauptvariation in den Daten, weshalb der Unterraum als der Informationsträger angesehen werden kann. Im Gegensatz dazu kann der Residual-Unterraum  $\mathbf{P}_{\text{res}}$  hinsichtlich seines Informationsgehalts vernachlässigt werden [58]. Wie in [88, 240] basiert die Wahl von  $\beta$  auf einem Schwellenwert, der sich auf die kumulative prozentuale Varianz (Cumulative-Percentage-Variance, CPV) stützt. Aus Gründen der Vergleichbarkeit beträgt der CPV-Wert nachfolgend stets 99.9%. Alternativen dazu wären das SCREE-Verfahren, die Kreuzvalidierung oder die Cut-off-Methode unter Verwendung des durchschnittlichen Eigenwerts [88, 157].

#### 4.4.2 Fehlerdetektion

Die PCA projiziert zur Überwachung alle Testdaten  $\mathbf{z}_t$  in die beiden von  $\mathbf{P}_{\text{pc}}$  und  $\mathbf{P}_{\text{res}}$  aufgespannten orthogonalen Unterräume [225]:

$$\mathbf{t}_t^{\text{pc}} = \mathbf{P}_{\text{pc}}^T \mathbf{z}_t \in \mathbb{S}_{\text{pc}} \equiv \text{span}\{\mathbf{P}_{\text{pc}}\} \quad (4.165)$$

$$\mathbf{t}_t^{\text{res}} = \mathbf{P}_{\text{res}}^T \mathbf{z}_t \in \mathbb{S}_{\text{res}} \equiv \text{span}\{\mathbf{P}_{\text{res}}\}. \quad (4.166)$$

Basierend auf den Projektionen in die beiden Unterräume ermöglichen zwei Teststatistiken die Erkennung von Anomalien im jeweiligen Unterraum [316]:

$$T^2(\mathbf{z}_t) = \mathbf{z}_t^T \mathbf{P}_{\text{pc}} \mathbf{\Lambda}_{\text{pc}}^{-1} \mathbf{P}_{\text{pc}}^T \mathbf{z}_t = (\mathbf{t}_t^{\text{pc}})^T \mathbf{\Lambda}_{\text{pc}}^{-1} \mathbf{t}_t^{\text{pc}} \quad (4.167)$$

$$\begin{aligned} Q(\mathbf{z}_t) &= \mathbf{z}_t^T \mathbf{P}_{\text{res}} \mathbf{P}_{\text{res}}^T \mathbf{z}_t = (\mathbf{t}_t^{\text{res}})^T \mathbf{t}_t^{\text{res}} \\ &= \mathbf{z}_t^T (\mathbf{I} - \mathbf{P}_{\text{pc}} \mathbf{P}_{\text{pc}}^T) \mathbf{z}_t = \mathbf{z}_t^T \mathbf{z}_t - (\mathbf{t}_t^{\text{pc}})^T \mathbf{t}_t^{\text{pc}}, \end{aligned} \quad (4.168)$$

mit der Einheitsmatrix  $\mathbf{I} \in \mathbb{R}^{m \times m}$ . Die  $T^2$ -Statistik entspricht dem in Abschnitt 2.4.3 eingeführten Mahalanobis-Abstand von  $\mathbf{z}_t$  zum Ursprung im PCA-Modellraum und die  $Q$ -Statistik dem quadratischen orthogonalen Abstand zum Ursprung des Residual-Raums [142]. Während die  $T^2$ -Statistik systematische Änderungen in den Eingangsdaten repräsentiert, zeigt die  $Q$ -Statistik zufällige oder unbekannte Variationen in den Messungen an [266].

Die Überwachung erfordert für beide Statistiken die Berechnung einer oberen Kontrollgrenze (Upper-Control-Limit, UCL). Diese berechnet sich aus den Teststatistiken für alle Trainingsdaten  $\mathbf{z}_\tau, \tau \in [1, N]$ . Wie in den Grundlagen in Abschnitt 2.4.2 eingeführt, setzt die PCA eine multivariate Normalverteilung der Daten voraus. Die nach (4.167) berechnete Statistik folgt deshalb einer  $T_{\beta, N-1}^2$ -Verteilung mit den Freiheitsgraden  $\beta$  und  $N - 1$  [102, Abschnitt 6.5.4.3.]. Das UCL der  $T^2$ -Statistik ist gegeben durch

$$T_{\text{UCL}}^2 = \frac{\beta(N^2 - 1)}{N(N - \beta)} F_\alpha(\beta, N - \beta), \quad (4.169)$$

wobei  $F_\alpha(\beta, N - \beta)$  der kritische Wert der F-Verteilung für ein Signifikanzniveau  $\alpha$  ist [316]. Die F-Verteilung

$$F_\alpha(\beta, N - \beta) = \frac{(N - \beta)\chi_\beta^2}{\beta\chi_{N-\beta}^2} \quad (4.170)$$

resultiert aus dem Quotienten zweier zentrierter  $\chi^2$ -Verteilungen mit den Freiheitsgraden  $\beta$  beziehungsweise  $N - \beta$ . Das UCL der  $Q$ -Statistik berechnet sich gemäß

$$Q_{\text{UCL}} = \theta_1 \left( \frac{h_0 c_\alpha \sqrt{2\theta_2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right)^{1/h_0} \quad (4.171)$$

mit

$$\theta_i = \sum_{j=\beta+1}^m \lambda_j^i \quad (4.172)$$

und

$$h_0 = 1 - \frac{2\theta_1\theta_3}{3\theta_2^2}. \quad (4.173)$$

Für ein Signifikanzniveau  $\alpha$  resultiert

$$c_\alpha = -\sqrt{2} \operatorname{erfc}^{-1}[2(1 - \alpha)] \quad (4.174)$$


aus der Fehlerfunktion

$$\operatorname{erfc}(x) = \frac{2}{\sqrt{\pi}} \int_x^\infty e^{-t^2} dt. \quad (4.175)$$

Nach der Berechnung der Prüfstatistiken und der zugehörigen UCLs gilt ein neues Mess-Sample  $\mathbf{z}_t$  als fehlerfrei, falls

$$T^2(\mathbf{z}_t) \leq T_{\text{UCL}}^2 \quad \text{und} \quad Q(\mathbf{z}_t) \leq Q_{\text{UCL}}. \quad (4.176)$$





**Abbildung 4.20:** Resultierende  $T^2$ - und  $Q$ -Statistiken nach Anwendung des linearen PCA-Monitorings auf den MDL-Datensatz für den Fall  $R_{\text{ISC}} = 10\Omega$ .

Andernfalls wird das überwachte Signal als abnormal betrachtet. Die  $T^2$ -Statistik erkennt Modellabweichungen, während die  $Q$ -Statistik ihre Kontrollgrenze überschreitet, wenn ein ungewöhnliches Ereignis und damit eine Änderung der Kovarianzstruktur auftritt [88].

Ein alternativer Ansatz zur Berechnung der UCLs besteht in der in Abschnitt 2.4.5 vorgestellten Kerndichteschätzung zur datengetriebenen Ermittlung der Verteilungen von  $T^2(\mathbf{z}_\tau)$  und  $Q(\mathbf{z}_\tau)$  mit  $\tau \in [1, N]$ . Die UCLs lassen sich dann basierend auf der geschätzten Verteilung und einem Signifikanzniveau  $\alpha$  ermitteln. Um eine Vergleichbarkeit der linearen Methode mit dem nichtlinearen Monitoring herzustellen, bei der eine analytische Berechnung der UCLs in dieser Form nicht möglich ist, erfolgt die Wahl der UCLs nachfolgend stets basierend auf einer Kerndichteschätzung mit einem Signifikanzniveau von  $\alpha = 99\%$ .

Nachdem die Teststatistiken  $T^2$  und  $Q$  definiert und zugehörige UCLs berechnet wurden, ist eine Fehlerdetektion möglich. Dies soll am Beispiel des 432-dimensionalen MDL-Datensatzes (siehe Abschnitt 4.2.5) demonstriert werden. Nach einer Vorverarbeitung der MDL-Daten, wie in Abschnitt 4.3 beschrieben, folgt das lineare PCA-Monitoring für den Fall  $R_{\text{ISC}} = 10\Omega$ . Abbildung 4.20 zeigt auf einer logarithmischen Skala die resultierenden  $T^2$ - und  $Q$ -Statistiken über der Zeit. Die Trainingsdaten sind in blau, die Testdaten in rot und die UCLs, basierend auf der Kerndichteschätzung, als durchgezogene Linie dargestellt. Beide Statistiken zeigen während der fehlerfreien Testperiode einen ähnlichen Verlauf wie im Training. Dies ist darauf zurückzuführen, dass die Verteilung der fehlerfreien Testdaten der des Trainings entspricht, wie es auch in den Abbildungen 4.18-4.19 zu beobachten ist. Direkt nach Auftreten des ISCs detektiert der Algorithmus durch die  $Q$ -Statistik eine Anomalie im Residual-Raum. Die Auffälligkeit ist im PCA-Modellraum mit der  $T^2$ -Statistik zunächst

noch nicht zu beobachten. Das heißt, die multivariate Verteilung folgt zunächst noch dem gelernten Datenmodell. Mit fortschreitendem Bestehen des ISCs und der damit einhergehenden Selbstentladung detektiert der Algorithmus auch eine Anomalie im Modellraum, sodass beide Kontrollstatistiken ihre UCLs überschreiten und ein Fehler erkannt wird. Aufgrund der anhaltenden Selbstentladung der Zellen und der größer werdenden Spannungsdifferenz nimmt auch der Betrag der Kontrollstatistiken zu.

Während beispielsweise die Berechnung der approximativen Entropie oder der Sample-Entropie eine Iteration über alle Samples erfordert, um die Vektorabstände zu berechnen [289, 312], ist die Berechnungskomplexität der vorliegenden Methode deutlich geringer. Die Online-Überwachung aus Abbildung 4.20 erfordert lediglich die Berechnung der beiden Teststatistiken gemäß den Gleichungen (4.167) und (4.168).

### 4.4.3 Fehlerisolation

Der bisher vorgestellte Algorithmus erlaubt bereits die Detektion interner Kurzschlüsse. Der nächste Schritt zur Fehlerdiagnose besteht in der Isolation, das heißt der Lokalisierung, der fehlerhaften Zelle im Batteriesystem. Die Fehlerisolation erfolgt durch die Analyse des Beitrags der einzelnen Variablen zur  $T^2$ - und  $Q$ -Statistik.

Beitragsdiagramme sind in der Literatur häufig genutzte Diagnosewerkzeuge zur Fehlerisolation [150, 184, 185, 199]. Hopkins, Miller u. a. haben 1995 die kommerzielle Nutzung patentiert [119, 225]. Aufgrund unterschiedlicher Definitionen der  $T^2$ -Statistik existieren verschiedene Ansätze, die Beiträge der einzelnen Variablen zur  $T^2$ -Statistik zu bestimmen. Miller, Swanson und Heckler berechnen zur Beitragsanalyse der  $T^2$ -Statistik den Beitrag jeder Variable zu jeder Dimension im Modellraum, was in der Praxis vor allem für hochdimensionale Signale, wie Spannungsvektoren von Batteriesystemen, sehr aufwendig sein kann [199, 224]. Zudem ist es möglich, die Querverbindungen zwischen den Variablen einzubeziehen oder zu eliminieren [225]. Der Beitrag zur  $Q$ -Statistik ist in der Literatur jedoch übereinstimmend definiert. Mit

$$\mathbf{z}_t^{\text{res}} = (\mathbf{I} - \mathbf{P}_{\text{pc}} \mathbf{P}_{\text{pc}}^T) \mathbf{z}_t \in \mathbb{R}^m \quad (4.177)$$

zerlegt die Beitragsanalyse die  $Q$ -Statistik im Residual-Raum in eine Summe

$$Q(\mathbf{z}_t) = \sum_{c=1}^m (z_{tc}^{\text{res}})^2 = \sum_{c=1}^m C_Q(z_{tc}) \quad (4.178)$$

über die Beiträge  $C_Q(z_{tc})$  zur  $Q$ -Statistik der  $c \in [1, m]$  Variablen zum Zeitpunkt  $t$  [225]. Inspiriert von diesem Ansatz erfolgt mit

$$\mathbf{z}_t^{\text{pc}} = \mathbf{P}_{\text{pc}} \boldsymbol{\Lambda}_{\text{pc}}^{-1} \mathbf{P}_{\text{pc}}^T \mathbf{z}_t \in \mathbb{R}^m \quad (4.179)$$

die Beitragsanalyse zur  $T^2$ -Statistik in dieser Arbeit analog


$$T^2(\mathbf{z}_t) = \sum_{c=1}^m (z_{tc}^{\text{pc}})^2 = \sum_{c=1}^m C_{T^2}(z_{tc}), \quad (4.180)$$

wobei  $C_{T^2}(z_{tc})$  dem Beitrag der  $c$ -ten Variable zum Zeitpunkt  $t$  entspricht. Die Variable mit dem größten Beitrag wird als die Variable betrachtet, die am meisten vom Fehler betroffen ist. Obwohl für die Erstellung der Beitragsdiagramme kein Vorwissen erforderlich ist, ist für die Interpretation der Diagramme oft Vorwissen über das überwachte System erforderlich. Die Variable mit dem größten Beitrag ist möglicherweise nicht die Ursache für den Fehler. Die Beitragsdiagramme identifizieren nur die Variablen, die von den normalen Betriebsbedingungen abweichen. In einigen Fällen ist es möglich, dass die Projektion den Beitrag einer Variablen auf andere Variablen verschiebt, was die Identifizierung der beitragenden Variablen erschwert [225].

Ausgehend vom Beispiel des vorhergehenden Abschnitts 4.4.2 und der erfolgreichen Detektion (siehe Abbildung 4.20) soll exemplarisch eine Fehlerisolation erfolgen. Dazu werden nach den Gleichungen 4.180 und 4.178 die mittleren Beiträge zur  $T^2$ - und  $Q$ -Statistik im Zeitraum  $t \in [4 \text{ h}, 8 \text{ h}]$  nach Auftreten des ISCs berechnet. Abbildung 4.21 zeigt die resultierenden Beitragsdiagramme für die beiden Kontrollstatistiken. Die Zelle 10, in der der ISC emuliert wird, ist in Rot dargestellt, die drei parallelen Zellen 9, 11, 12 sind in Orange gekennzeichnet, die verbleibenden 428 Zellen sind in grau dargestellt. Bereits im Zeitraum  $t \in [4 \text{ h}, 8 \text{ h}]$  nach dem Fehler lässt sich die detektierte Anomalie in beiden Kontrolldiagrammen eindeutig auf die Zellen  $c \in [9, 12]$  eingrenzen, auch wenn die  $T^2$ -Statistik in diesem Zeitraum ihr UCL zeitweise noch unterschreitet (siehe Abbildung 4.20).

Da sich die Wechselwirkungen serieller Zellen vernachlässigen lassen, erfolgt keine Verschiebung der Beiträge auf die anderen Variablen. Die Beitragsdiagramme entfalten somit ihr volles Potential zur Lokalisierung auffälliger Zellen. Die Anomalie lässt sich jedoch nur auf den betroffenen Parallelstrang einschränken. Wie von Qin angemerkt, korrespondiert bei zusammenhängenden, interagierenden Variablen nicht automatisch die Variable mit dem größten Beitrag zum fehlerhaften Signal [225]. Diesen Zusammenhang verdeutlicht auch das gewählte Beispiel, bei dem die fehlerhafte Zelle 10 jeweils nur den zweitgrößten Beitrag zu den beiden Kontrollstatistiken liefert. Am meisten trägt jedoch Zelle 9 bei, die die fehlerhafte Zelle zwar speist, selbst jedoch nicht vom ISC betroffen ist.

Zusammenfassend lässt sich daraus ableiten, dass sich der fehlerhafte Parallelverbund mit den Beitragsdiagrammen eindeutig isolieren lässt. In rein seriell verschalteten Batteriepacks, wie in den SMG-, PAN- und PHEV-Daten, resultiert daraus bereits eine vollständige Fehlerisolation auf Zellebene. In Batteriepacks mit Parallelschaltung lässt sich jedoch nur der betroffene Parallelstrang lokalisieren. Es sollte bei der Fehlerisolation also nicht fälschlicherweise vom größten Beitrag auf die fehlerhafte Einzelzelle geschlossen werden. Eine




**Abbildung 4.21:** Beitrag der einzelnen Zellspannungen zur  $T^2$ - und  $Q$ -Statistik im Zeitraum  $t \in [4\text{ h}, 8\text{ h}]$  nach Auftreten des  $10\Omega$ -ISCs für den MDL-Datensatz.

weiterführende Lokalisierung ermöglichen aber beispielsweise die in Kapitel 5 behandelten rekonfigurierbaren Batteriesysteme, die ein Deaktivieren und Überbrücken einzelner Zellen zulassen [238].

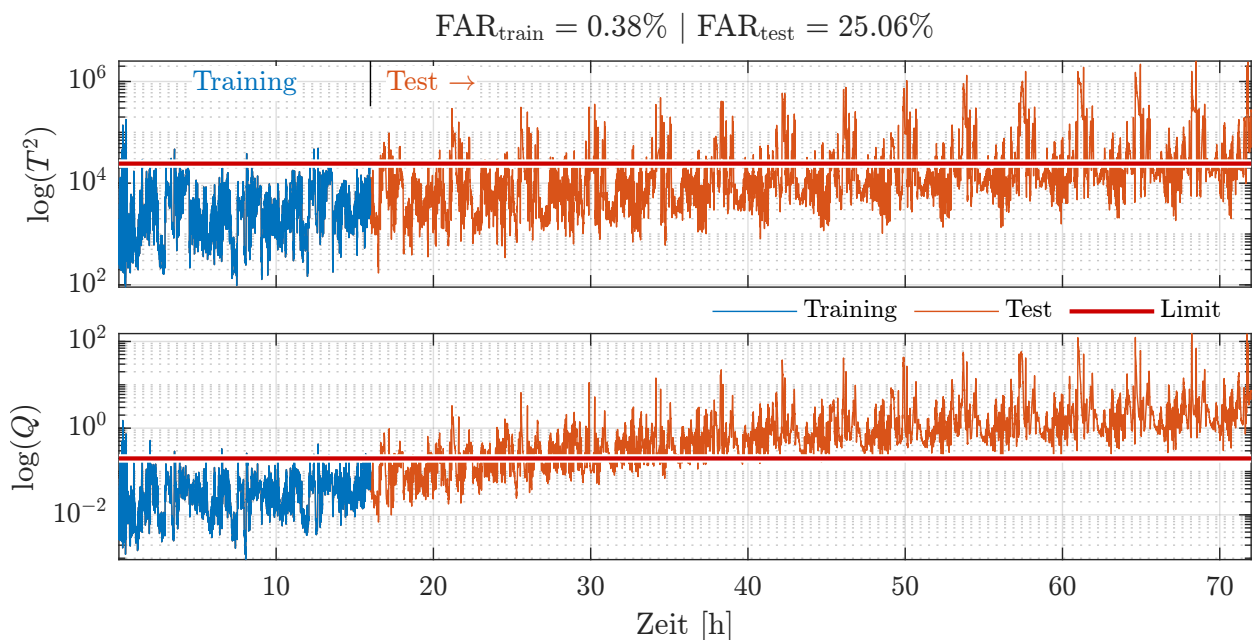
#### 4.4.4 Berücksichtigung von Nicht-Stationaritäten

Die zuvor beschriebenen Methoden dienen als Ausgangspunkt für die Fehlerdiagnose. In realen Batteriesystemen ändern sich jedoch die Betriebsbedingungen und Zellparameter ständig. Änderungen der Temperatur, des SOC oder der Alterung verursachen ein nicht-stationäres Verhalten. Das gelernte Datenmodell würde dann nicht mehr mit den Sensordaten übereinstimmen.

Um diesen Effekt exemplarisch zu zeigen simuliert das Modell aus Abschnitt 4.2.5 eine beschleunigte Alterung des Batteriepacks. Die dynamische Anregung entspricht der in Abschnitt 4.2.5 beschriebenen. Die Zellen besitzen zu Beginn der Simulation eine mittlere Kapazität von 23 Ah mit einer Parametervariation von 1 % (siehe Abbildung 4.22). Im Laufe der simulierten 72 h verringert sich die Kapazität aller Zellen kontinuierlich und die Parametervariation nimmt zu. Zum Ende der Simulation beträgt die Zellkapazität im Mittel 18.4 Ah



**Abbildung 4.22:** Zellkapazitäten zu Beginn ( $\mu_Q = 23 \text{ Ah}$ ,  $\sigma_Q = 0.23 \text{ Ah}$ ) und zum Ende einer beschleunigten Alterungssimulation ( $\mu_Q = 18.4 \text{ Ah}$ ,  $\sigma_Q = 0.92 \text{ Ah}$ ).



**Abbildung 4.23:** Resultierende  $T^2$ - und  $Q$ -Statistiken nach Anwendung des linearen PCA-Monitorings während einer beschleunigten Alterung des Batteriepacks.

(80% des Ausgangswerts) bei einer Variation von 5%, wie Abbildung 4.22 in Rot zeigt. Die Innenwiderstände der Zellen variieren zu Beginn der Simulation um 3% (analog zu Abbildung 4.16) und erhöhen sich während der Simulation kontinuierlich. Zum Simulationsende besitzen die Zellen den 1.5-fachen Innenwiderstand bei einer Parametervariation von 18%. Abbildung 4.23 zeigt die Anwendung des linearen PCA-Monitorings, wie in Abschnitt 4.4.2 vorgestellt. Das Training erfolgt in den ersten 16 h, die anschließenden 56 h entsprechen dem Test. Während des Tests tritt kein ISC auf, lediglich die beschleunigte Alterung verschlechtert die Homogenität des Batteriepacks. Es ist zu beobachten, dass sich beide Kontrollstatistiken während des Tests über den Schwellwert bewegen und dieser nicht mehr dem in Training

gewählten Signifikanzniveau von  $\alpha = 99\%$  entspricht. Dies liegt daran, dass das in den ersten 16 h gelernte Datenmodell die multivariate Verteilung der Zellspannungen mit zunehmender Alterung immer schlechter beschreiben kann. Auf diese Weise kommt während des Tests eine Fehlalarmrate  $\text{FAR}_{\text{test}}$  von mehr als 25% zustande. Dies motiviert eine Erweiterung der vorgestellten Fehlerdiagnose, die das Modell im fehlerfreien Betrieb kontinuierlich an die Daten anpasst. In der Literatur sind zwei Ansätze bekannt, um Nicht-Stationaritäten zu begegnen: die rekursive Hauptkomponentenanalyse (Recursive-Principal-Component-Analysis, RPCA) und die gleitende Hauptkomponentenanalyse (Moving-Window-Principal-Component-Analysis, MWPCA) [142].

### Rekursive Hauptkomponentenanalyse (RPCA)

Die Idee, neue Beobachtungen zu verwenden, um das Datenmodell im Falle von Nicht-Stationaritäten anzupassen, wurde erstmals von Wold sowie Gallagher, Wise u. a. untersucht [84, 294]. Diese beiden Ansätze erfordern jedoch die Gesamtheit aller historischen Daten und eine vollständige Neuberechnung der Parameter zu jedem Zeitpunkt [142]. Diese Arbeit verfolgt einen effizienteren Aktualisierungsansatz, den Li, Yue u. a. vorgestellt haben [161]. Die Methode ermöglicht ein direktes Update der Parameter.

Ist ein neuer Vektor  $\mathbf{z}_t$  an Testdaten vorhanden, wird dieser zunächst basierend auf dem vorhandenen Datenmodell bewertet. Wenn die  $T^2$ - und  $Q$ -Statistiken ihren Grenzwert überschreiten, was auf einen Fehler oder einen Ausreißer hinweist, so wird das Modell nicht aktualisiert. Ansonsten erfolgt eine Aktualisierung des geschätzten Mittelwerts, der Standardabweichung und der Kovarianzmatrix [142]. In der Praxis wird das Datenmodell vom Zeitschritt  $k$  nach  $k + 1$  nicht nach jeder fehlerfreien Beobachtung aktualisiert, sondern im Allgemeinen nach einem Block  $\mathbf{X}_{n_{k+1}} = [\mathbf{x}_{N_k+1} \dots \mathbf{x}_{N_{k+1}}]^T \in \mathbb{R}^{n_{k+1} \times m}$ , bestehend aus  $n_{k+1}$  fehlerfreien Vektoren mit der Schreibweise  $N_k = \sum_{\tau=1}^k n_\tau$  beziehungsweise  $N_{k+1} = \sum_{\tau=1}^{k+1} n_\tau = N_k + n_{k+1}$ . Die Matrix

$$\mathbf{X}_{k+1} = \begin{bmatrix} \mathbf{X}_k \\ \mathbf{X}_{n_{k+1}} \end{bmatrix} \in \mathbb{R}^{N_{k+1} \times m} \quad (4.181)$$

entspricht der Gesamtheit aller Daten zum Zeitpunkt  $k + 1$ , mit  $\mathbf{X}_k \in \mathbb{R}^{N_k \times m}$ . Das Update der Kovarianzmatrix von  $\mathbf{C}_k$  nach

$$\mathbf{C}_{k+1} = \frac{1}{N_{k+1} - 1} \mathbf{Z}_{k+1}^T \mathbf{Z}_{k+1} \quad (4.182)$$

erfordert die Berechnung von  $\mathbf{Z}_{k+1}$  basierend auf dem Datenblock  $\mathbf{X}_{k+1}$ . Nachfolgend werden deshalb der Mittelwert  $\bar{\xi}_{c,k+1}$  und die Standardabweichung  $s_{c,k+1}$  der  $c$ -ten Spalte  $\boldsymbol{\zeta}_{c,k+1}$  von

$\mathbf{Z}_{k+1} = [\zeta_{1,k+1}, \dots, \zeta_{c,k+1}, \dots, \zeta_{m,k+1}] \in \mathbb{R}^{N_{k+1} \times m}$  berechnet. Aus der Beziehung

$$\left( \sum_{\tau=1}^{k+1} n_{\tau} \right) \bar{\xi}_{c,k+1} = \left( \sum_{\tau=1}^k n_{\tau} \right) \bar{\xi}_{c,k} + \sum_{\tau=1}^{n_{k+1}} \xi_{c,\tau} \quad (4.183)$$

folgt direkt die Rekursionsvorschrift für den Mittelwert

$$\bar{\xi}_{c,k+1} = \frac{N_k}{N_{k+1}} \bar{\xi}_{c,k} + \frac{1}{N_{k+1}} \sum_{\tau=1}^{n_{k+1}} \xi_{c,\tau}. \quad (4.184)$$

Für das Update der Standardabweichung folgt gemäß Gleichung (4.154)

$$s_{c,k+1} = \sqrt{\frac{1}{N_{k+1} - 1} \sum_{\tau=1}^{N_{k+1}} (\xi_{c,\tau} - \bar{\xi}_{c,k+1})^2}. \quad (4.185)$$

Eine Umformung liefert

$$\begin{aligned} (N_{k+1} - 1) s_{c,k+1}^2 &= \sum_{\tau=1}^{N_{k+1}} (\xi_{c,\tau} - \bar{\xi}_{c,k+1})^2 \\ &= \sum_{\tau=1}^{N_k} (\xi_{c,\tau} - \bar{\xi}_{c,k+1})^2 + \sum_{\tau=1}^{n_{k+1}} (\xi_{c,\tau} - \bar{\xi}_{c,k+1})^2. \end{aligned} \quad (4.186)$$

Mit

$$\Delta \bar{\xi}_{c,k+1} = \bar{\xi}_{c,k+1} - \bar{\xi}_{c,k} \quad (4.187)$$

folgt

$$(N_{k+1} - 1) s_{c,k+1}^2 = \sum_{\tau=1}^{N_k} (\xi_{c,\tau} - \bar{\xi}_{c,k} - \Delta \bar{\xi}_{c,k+1})^2 + \sum_{\tau=1}^{n_{k+1}} (\xi_{c,\tau} - \bar{\xi}_{c,k+1})^2 \quad (4.188)$$

woraus unter Verwendung von  $\sum_{\tau=1}^{N_k} (\xi_{c,\tau} - \bar{\xi}_{c,k}) = 0$

$$(N_{k+1} - 1) s_{c,k+1}^2 = \sum_{\tau=1}^{N_k} (\xi_{c,\tau} - \bar{\xi}_{c,k})^2 + N_k \Delta \bar{\xi}_{c,k+1}^2 + \sum_{\tau=1}^{n_{k+1}} (\xi_{c,\tau} - \bar{\xi}_{c,k+1})^2 \quad (4.189)$$

resultiert [161]. Die Umformung von (4.188) nach (4.189) zeigt der Anhang A.4. Mit  $(N_k - 1) s_{c,k}^2 = \sum_{\tau=1}^{N_k} (\xi_{c,\tau} - \bar{\xi}_{c,k})^2$  folgt für die Rekursionsvorschrift

$$s_{c,k+1} = \sqrt{\frac{N_k - 1}{N_{k+1} - 1} s_{c,k}^2 + \frac{N_k}{N_{k+1} - 1} \Delta \bar{\xi}_{c,k+1}^2 + \frac{1}{N_{k+1} - 1} \sum_{\tau=1}^{n_{k+1}} (\xi_{c,\tau} - \bar{\xi}_{c,k+1})^2}, \quad (4.190)$$

um die Standardabweichung  $s_{c,k+1}$  aus  $s_{c,k}$  zu berechnen. Der Mittelwert  $\bar{\xi}_{c,k+1}$  und die Standardabweichung  $s_{c,k+1}$  ermöglichen eine Berechnung der  $c$ -ten Spalte  $\zeta_{c,k+1}$  von  $\mathbf{Z}_{k+1}$

basierend auf der Spalte  $\boldsymbol{\xi}_{c,k+1}$  der Datenmatrix  $\mathbf{X}_{k+1}$ :

$$\begin{aligned}\zeta_{c,k+1} &= \frac{\boldsymbol{\xi}_{c,k+1} - \bar{\xi}_{c,k+1} \mathbf{1}_{k+1}}{s_{c,k+1}} \\ &= \begin{bmatrix} \boldsymbol{\xi}_{c,k} - \bar{\xi}_{c,k+1} \mathbf{1}_k \\ \boldsymbol{\xi}_{c,n_{k+1}} - \bar{\xi}_{c,k+1} \mathbf{1}_{n_{k+1}} \end{bmatrix} s_{c,k+1}^{-1} \\ &= \begin{bmatrix} \boldsymbol{\xi}_{c,k} - \bar{\xi}_{c,k} \mathbf{1}_k - \Delta \bar{\xi}_{c,k+1} \mathbf{1}_k \\ \boldsymbol{\xi}_{c,n_{k+1}} - \bar{\xi}_{c,k+1} \mathbf{1}_{n_{k+1}} \end{bmatrix} s_{c,k+1}^{-1},\end{aligned}\quad (4.191)$$

mit der Schreibweise  $\mathbf{1}_k \in \mathbb{R}^{N_k}$ . Mit  $\zeta_{c,k} = (\boldsymbol{\xi}_{c,k} - \bar{\xi}_{c,k} \mathbf{1}_k) s_{c,k}^{-1}$  und  $\zeta_{c,n_{k+1}} = (\boldsymbol{\xi}_{c,n_{k+1}} - \bar{\xi}_{c,k+1} \mathbf{1}_{n_{k+1}}) s_{c,k+1}^{-1}$  folgt die rekursive Vorschrift

$$\zeta_{c,k+1} = \begin{bmatrix} \zeta_{c,k} s_{c,k} s_{c,k+1}^{-1} - \Delta \bar{\xi}_{c,k+1} s_{c,k+1}^{-1} \mathbf{1}_k \\ \zeta_{c,n_{k+1}} \end{bmatrix} \quad (4.192)$$

für die Spalten der Matrix  $\mathbf{Z}_{k+1}$ . Unter Verwendung der Matrix-Vektor-Schreibweise  $\mathbf{S} = \text{diag}(s_1, \dots, s_c, \dots, s_m) \in \mathbb{R}^{m \times m}$  und  $\bar{\boldsymbol{\xi}} = [\bar{\xi}_1, \dots, \bar{\xi}_c, \dots, \bar{\xi}_m]^T \in \mathbb{R}^m$  folgt

$$\mathbf{Z}_{k+1} = \begin{bmatrix} \mathbf{Z}_k \mathbf{S}_k \mathbf{S}_{k+1}^{-1} - \mathbf{1}_k \Delta \bar{\boldsymbol{\xi}}_{k+1} \mathbf{S}_{k+1}^{-1} \\ \mathbf{Z}_{n_{k+1}} \end{bmatrix}. \quad (4.193)$$

Mit (4.193) folgt für die Kovarianzmatrix

$$\begin{aligned}\mathbf{C}_{k+1} &= \frac{1}{N_{k+1} - 1} \mathbf{Z}_{k+1}^T \mathbf{Z}_{k+1} \\ &= \frac{1}{N_{k+1} - 1} \mathbf{S}_{k+1}^{-1} \mathbf{S}_k \mathbf{Z}_k^T \mathbf{Z}_k \mathbf{S}_k \mathbf{S}_{k+1}^{-1} \\ &\quad + \frac{1}{N_{k+1} - 1} \mathbf{1}_k^T \mathbf{1}_k \mathbf{S}_{k+1}^{-1} \Delta \bar{\boldsymbol{\xi}}_{k+1} \Delta \bar{\boldsymbol{\xi}}_{k+1}^T \mathbf{S}_{k+1}^{-1} \\ &\quad - \frac{2}{N_{k+1} - 1} \mathbf{S}_{k+1}^{-1} \Delta \bar{\boldsymbol{\xi}}_{k+1} \mathbf{1}_k^T \mathbf{Z}_k \mathbf{S}_k \mathbf{S}_{k+1}^{-1} \\ &\quad + \frac{1}{N_{k+1} - 1} \mathbf{Z}_{n_{k+1}}^T \mathbf{Z}_{n_{k+1}}.\end{aligned}\quad (4.194)$$

Mit  $\mathbf{1}_k^T \mathbf{Z}_k = 0$ ,  $\mathbf{1}_k^T \mathbf{1}_k = N_k$  und  $\mathbf{Z}_k^T \mathbf{Z}_k = (N_k - 1) \mathbf{C}_k$  folgt direkt die Rekursionsvorschrift

$$\begin{aligned}\mathbf{C}_{k+1} &= \frac{N_k - 1}{N_{k+1} - 1} \mathbf{S}_{k+1}^{-1} \mathbf{S}_k \mathbf{C}_k \mathbf{S}_k \mathbf{S}_{k+1}^{-1} \\ &\quad + \frac{N_k}{N_{k+1} - 1} \mathbf{S}_{k+1}^{-1} \Delta \bar{\boldsymbol{\xi}}_{k+1} \Delta \bar{\boldsymbol{\xi}}_{k+1}^T \mathbf{S}_{k+1}^{-1} \\ &\quad + \frac{1}{N_{k+1} - 1} \mathbf{Z}_{n_{k+1}}^T \mathbf{Z}_{n_{k+1}}.\end{aligned}\quad (4.195)$$



Soll der Einfluss älterer Daten reduziert werden, ermöglicht die Einführung eines Vergessensfaktors  $\eta$  das Gewicht historischer Beobachtungen exponentiell zu verringern. Zudem gilt nach längerem Betrieb  $N_k \gg 1$ . Die angepassten Rekursionsformeln zum Update mit  $n_{k+1} \times m$ -Block für  $N_k \gg 1$  mit Vergessensfaktor  $\eta$  lauten [161]:

$$\bar{\xi}_{x,k+1} = \eta \bar{\xi}_{x,k} + (1 - \eta) \frac{1}{n_{k+1}} \sum_{\tau=1}^{n_{k+1}} x_{\tau c}, \quad (4.196)$$

$$s_{c,k+1} = \sqrt{\eta(s_{c,k}^2 + \Delta \bar{\xi}_{c,k+1}^2) + (1 - \eta) \frac{1}{n_{k+1} - 1} \sum_{\tau=1}^{n_{k+1}} (x_{\tau c} - \bar{\xi}_{c,k+1})^2} \quad (4.197)$$

und


$$\begin{aligned} \mathbf{C}_{k+1} = & \eta \mathbf{S}_{k+1}^{-1} \left( \mathbf{S}_k \mathbf{C}_k \mathbf{S}_k + \Delta \bar{\boldsymbol{\xi}}_{k+1} \Delta \bar{\boldsymbol{\xi}}_{k+1}^T \right) \mathbf{S}_{k+1}^{-1} \\ & + (1 - \eta) \frac{1}{N_{k+1} - 1} \mathbf{Z}_{n_{k+1}}^T \mathbf{Z}_{n_{k+1}}. \end{aligned} \quad (4.198)$$

Durch die Verwendung eines Vergessensfaktors bleibt der Einfluss älterer Daten im PCA-Modell erhalten. Somit nutzt der Algorithmus historische Daten, die als Erfahrungswerte des Datenmodells gelten, für den Umgang mit ungewöhnlichem Prozessverhalten. Die Anpassung der Kovarianzmatrix entspricht einer Rang-1-Modifikation, was den Vorteil hat, dass das Eigenwertproblem nicht für jedes Update neu gelöst werden muss, sondern effiziente Algorithmen zur Berechnung der Eigenwerte und -vektoren existieren [25, 161]. Anhang A.3 liefert die Berechnungsvorschrift für eine Rang-1-Modifikation des symmetrischen Eigenwertproblems.

Abbildung 4.24 zeigt eine Anwendung der RPCA auf das zu Beginn des Abschnitts eingeführte Beispiel. Die Initialisierung des Datenmodells erfolgt wie in Abbildung 4.23 mit den ersten 16 h der Simulationsdaten. Nach der Initialisierung passt sich das Datenmodell nach Blöcken mit einer konstanten Größe von  $N_k = N_{k+1} = 1000$ , was etwa 2.78 h entspricht, kontinuierlich an. Der Vergessensfaktor für jeden Block beträgt  $\eta = 0.9$ , was vergleichbar mit einem Sample-weisem Vergessensfaktor von  $\eta = \sqrt[1000]{0.9} \approx 0.9999$  ist. Wie Abbildung 4.24 zeigt, ist das Datenmodell durch die rekursive Erweiterung in der Lage, dem nicht-stationären Verhalten während der Alterung des Batteriepacks zu folgen. Verglichen zum Training ( $\text{FAR}_{\text{train}} = 0.38\%$ ) ist eine leicht erhöhte Fehlalarmrate von  $\text{FAR}_{\text{test}} = 1.93\%$  zu beobachten, die jedoch in Relation zu der stark beschleunigten Alterungssimulation vertretbar ist.

### Gleitende Hauptkomponentenanalyse (MWPCA)

Während bei der RPCA durch die Verwendung eines Vergessensfaktors der Einfluss älterer Daten im PCA-Modell erhalten bleibt, definiert bei der MWPCA eine feste Anzahl an Samples das Datenmodell. Stehen neue fehlerfreie Daten zur Verfügung, verschiebt sich das Fenster auf dessen Basis sich das PCA-Modell stützt. Ältere Daten fließen in das PCA-



**Abbildung 4.24:** Resultierende  $T^2$ - und  $Q$ -Statistiken nach Anwendung der RPCA während einer beschleunigten Alterung des Batteriepacks.

Modell nicht mehr ein. Nach einer Vorverarbeitung der Daten gemäß Abschnitt 4.3.1 erfolgt das Training des PCA-Modells mit den  $N$  letzten Samples, die die Schwellwerte der beiden Kontrollstatistiken nicht überschritten haben [142]. Um eine Neuberechnung des Datenmodells in jedem Schritt zu vermeiden, existieren auch für die MWPCA effiziente Methoden, die den Rechenaufwand auf Rang-1-Modifikationen der Kovarianzmatrix reduzieren [128]. Sei  $\mathbf{X}_k = [\mathbf{x}_{k-N+1}, \mathbf{x}_{k-N+2}, \dots, \mathbf{x}_k]^T \in \mathbb{R}^{N \times n}$  die Matrix mit den  $N$  Vektoren zum Zeitpunkt  $k$ ,  $\mathbf{X}_{k+1} = [\mathbf{x}_{k-N+2}, \mathbf{x}_{k-N+3}, \dots, \mathbf{x}_{k+1}]^T \in \mathbb{R}^{N \times n}$  die Matrix mit den  $N$  Vektoren zum Zeitpunkt  $k+1$  und  $\mathbf{X}' = [\mathbf{x}_{k-N+2}, \mathbf{x}_{k-N+3}, \dots, \mathbf{x}_k]^T \in \mathbb{R}^{(N-1) \times n}$  die Matrix, die alle  $N-1$  gemeinsamen, sich überschneidenden Vektoren der beiden Matrizen  $\mathbf{X}_k$  und  $\mathbf{X}_{k+1}$  enthält [151]. Um den Einfluss des ältesten Samples  $\mathbf{x}_{k-N+1}$  aus  $\mathbf{X}_k$  zu eliminieren, erfolgt eine Neuberechnung des Mittelwerts


$$\bar{\mathbf{x}}' = \frac{N}{N-1} \bar{\mathbf{x}}_k - \frac{1}{N-1} \mathbf{x}_{k-N+1} \quad (4.199)$$

und der Kovarianzmatrix

$$\mathbf{C}' = \frac{N-1}{N-2} \left( \mathbf{C}_k - \frac{1}{N-1} \mathbf{z}_{k-N+1} \mathbf{z}_{k-N+1}^T - \Delta \bar{\mathbf{x}}'_k (\Delta \bar{\mathbf{x}}'_k)^T \right), \quad (4.200)$$

wobei  $\Delta \bar{\mathbf{x}}'_k = \bar{\mathbf{x}}_k - \bar{\mathbf{x}}'$  ist. Ähnlich wie bei der RPCA folgen die Rekursionsformeln

$$\bar{\mathbf{x}}' = \frac{N-1}{N} \bar{\mathbf{x}}' - \frac{1}{N} \mathbf{x}_{k+1} \quad (4.201)$$



**Abbildung 4.25:** Resultierende  $T^2$ - und  $Q$ -Statistiken nach Anwendung der MWPCA während einer beschleunigten Alterung des Batteriepacks.

und

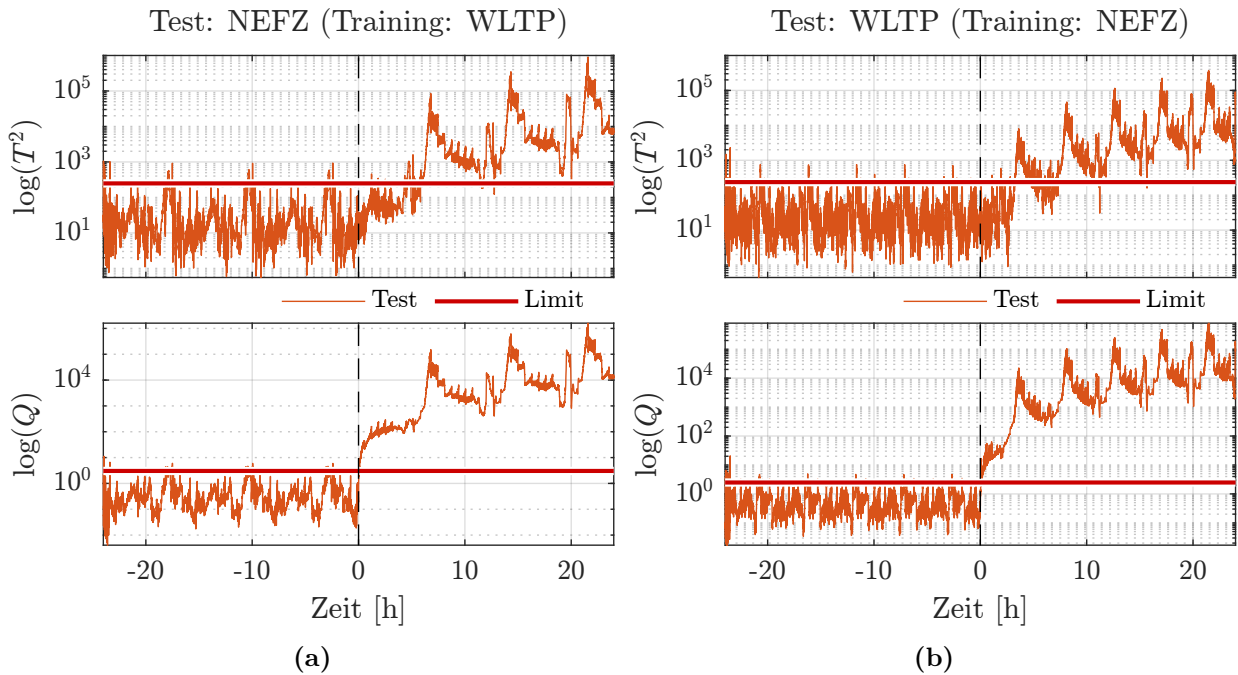
$$\mathbf{C}_{k+1} = \frac{N-2}{N-1} \mathbf{C}' + \frac{1}{N-1} \mathbf{z}_{k+1} \mathbf{z}_{k+1}^T + \Delta \bar{\mathbf{x}}'_{k+1} (\Delta \bar{\mathbf{x}}'_{k+1})^T \quad (4.202)$$

für das Update von  $\mathbf{X}_k$  nach  $\mathbf{X}_{k+1}$ , wobei  $\Delta \bar{\mathbf{x}}'_{k+1} = \bar{\mathbf{x}}_{k+1} - \bar{\mathbf{x}}'$  ist. Durch Einsetzen von (4.200) in (4.202) folgt schließlich

$$\begin{aligned} \mathbf{C}_{k+1} = \mathbf{C}_k &- \frac{1}{N-1} \mathbf{z}_{k-N+1} \mathbf{z}_{k-N+1}^T \\ &- \Delta \bar{\mathbf{x}}'_k (\Delta \bar{\mathbf{x}}'_k)^T \\ &+ \frac{1}{N-1} \mathbf{z}_{k+1} \mathbf{z}_{k+1}^T \\ &+ \Delta \bar{\mathbf{x}}'_{k+1} (\Delta \bar{\mathbf{x}}'_{k+1})^T \end{aligned} \quad (4.203)$$

was vier Rang-1-Modifikationen der Kovarianzmatrix nach dem in Anhang A.3 beschriebenen Vorgehen entspricht. Kruger und Xie liefern einen detaillierten Vergleich der Berechnungszeit für verschiedene Methoden zur Aktualisierung der Eigenwertzerlegung [151, Kapitel 7].

Abbildung 4.25 zeigt die Anwendung der MWPCA auf das zu Beginn des Abschnitts vorgestellte Beispiel. Die ersten 16 h dienen zur Initialisierung des Datenmodells, in den restlichen 56 h erfolgt der Test für die fehlerfreien Batteriepackdaten während einer beschleunigten Alterungssimulation. Die Fenstergröße beträgt konstant  $N = 5760$ , was zu Beginn 16 h entspricht und sich im Laufe der Zeit geringfügig verlängert. Dies liegt daran, dass sich das Datenmodell für die Zeitpunkte, zu denen beide Statistiken ihren Grenzwert überschreiten, nicht aktualisiert. Ähnlich wie in Abbildung 4.24 ist die Fehlalarmrate von FAR<sub>test</sub> = 2.11 %



**Abbildung 4.26:** Resultierende  $T^2$ - und  $Q$ -Statistik nach Anwendung des linearen PCA-Monitorings auf den MDL-Datensatz für den Fall  $R_{\text{ISC}} = 10 \Omega$  und unterschiedlichen Anregungen im Training und Test.

während des Tests verglichen mit der Fehlalarmrate während des Trainings leicht erhöht.

#### 4.4.5 Kreuzvalidierung

In den bisherigen Untersuchungen wurde stets ein WLTP-basiertes Stromprofil zur Anregung des Batteriesystems verwendet. Generell ist die Anregung mit standardisierten Fahrzyklen für die gegebene Sensorgüte und Abtastrate vergleichbar mit den Anregungen, wie sie bei realen Straßenfahrten auftreten (vergleiche Abschnitt 4.2.4). Um jedoch auszuschließen, dass fahrzyklusspezifische Eigenschaften gelernt werden und die Generalisierungsfähigkeit des Datenmodells zu bewerten, erfolgt das Training und der Test nachfolgend mit unterschiedlichen Fahrzyklen. Als weites Anregungsprofil dient ein Stromprofil, basierend auf dem neuen europäischen Fahrzyklus (NEFZ) mit dem das Modell, wie in Abschnitt 4.2.5 beschrieben, angeregt wird. Abbildung 4.26a zeigt die resultierenden Kontrollstatistiken für NEFZ-basierte Testdaten nach dem Training mit einem WLTP-basierten Stromprofil. Der Trainingszeitraum beträgt 8 h. Eine Kerndichteschätzung bestimmt die UCLs basierend auf den resultierenden Kontrollstatistiken im Training. Im Test tritt zum Zeitpunkt  $t = 0$  h ein ISC von  $R_{\text{ISC}} = 10 \Omega$  auf. Während der fehlerfreien Testperiode  $t \in [-24 \text{ h}, 0 \text{ h}]$  in Abbildung 4.26a wird deutlich, dass die geschätzten UCLs auch für die NEFZ-basierten Testdaten eine sinnvolle Schranke darstellen. Dies bestätigt auch Abbildung 4.26b, die die resultierenden Kontrollstatistiken für WLTP-basierte Testdaten nach Training mit NEFZ-basierten Daten zeigt. Direkt nach Auftreten des ISCs ist eine signifikante Anomalie im Residual-Raum zu beobachten. Im

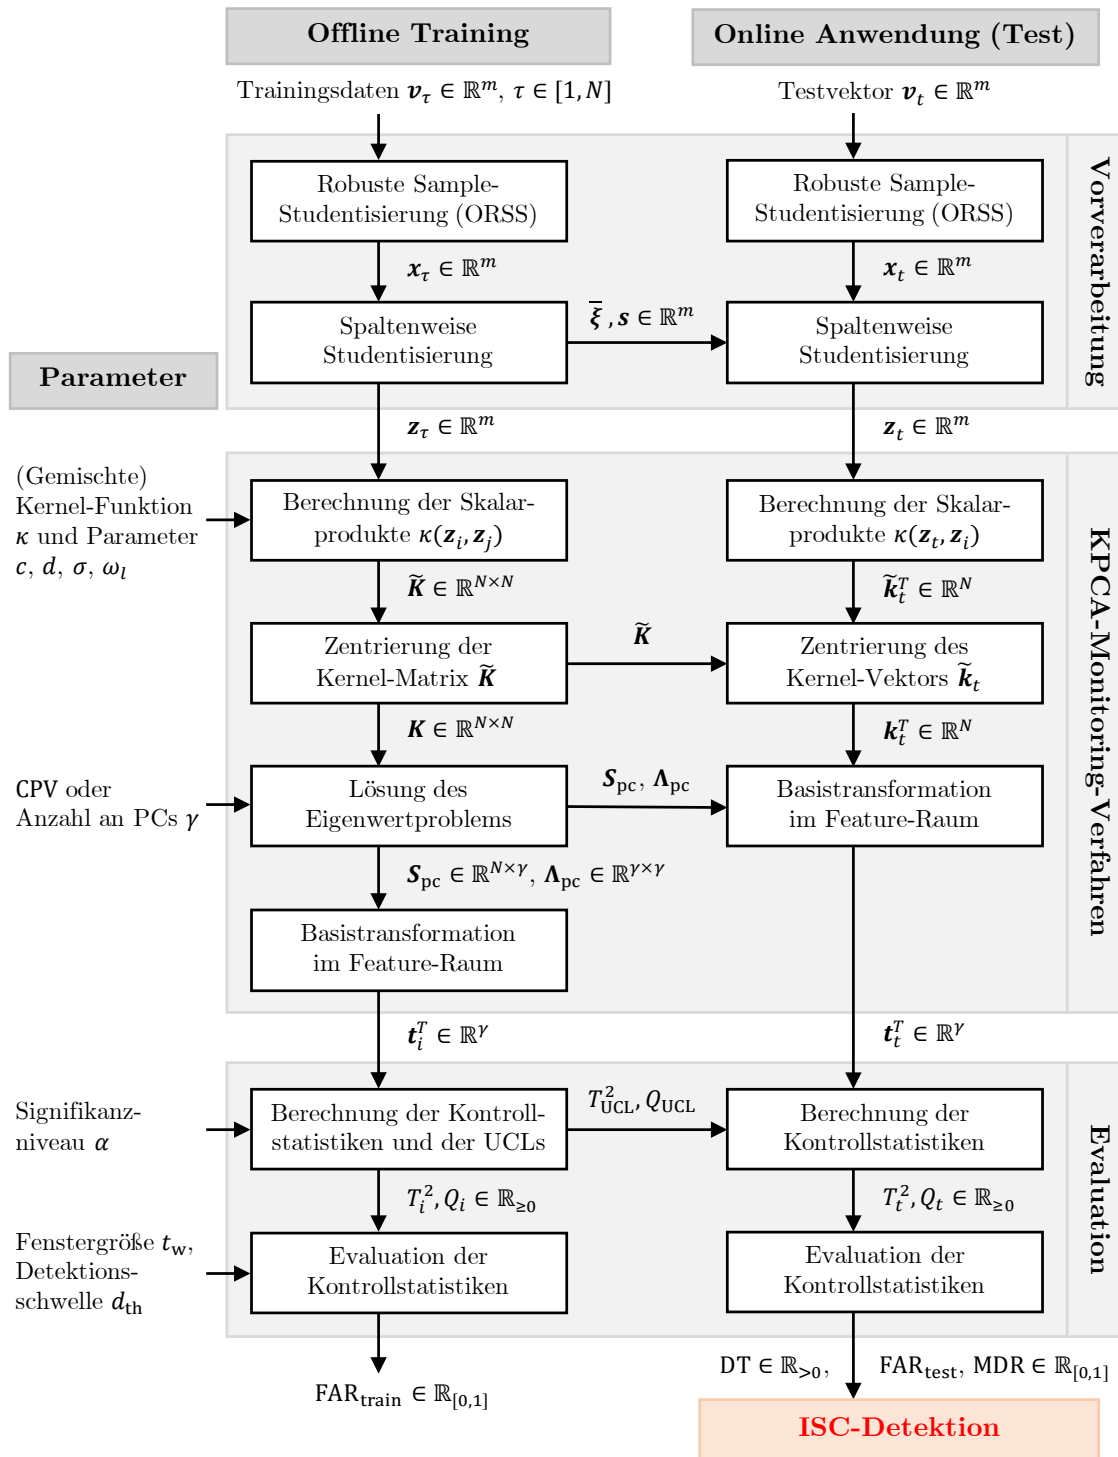
Modellraum lässt sich die Auffälligkeit, ähnlich wie in Abschnitt 4.4.2, nach etwa 8 h eindeutig detektieren. In beiden Fällen wird erkannt das Verfahren im Normalbetrieb kein Fehler und stellt im Fehlerfall eine Anomalie fest. Daraus lässt sich schließen, dass die Methode in der Lage ist, unterschiedliche Anregungsdaten zu verallgemeinern.

## 4.5 Nichtlineares Zellmonitoring

Wie Abbildung 4.19 zeigt, sind vor allem mit zunehmenden Parametervariationen zwischen den Batteriezellen systematische, nichtlineare Variationen zu beobachten. Um diesen Nichtlinearitäten und nicht-Gaußschem Rauschen zu begegnen, erfolgt in diesem Abschnitt eine Erweiterung der im vorangegangenen Abschnitt 4.4 vorgestellten linearen Methode. Für die Anpassung des Verfahrens kommt die in Abschnitt 2.4.4 eingeführte Kernel-Methode zum Einsatz. Abbildung 4.27 fasst die Schritte des vollständigen Prozederes sowie alle Schnittstellen zusammen. Die Datenvorverarbeitung mit der ORSS und der spaltenweisen Studentisierung sowie die Evaluation der transformierten Projektion entsprechen den im vorangegangenen Abschnitt 4.4 vorgestellten Verfahren. Das KPCA-Monitoring-Verfahren erweitert die lineare Methode um eine Transformation der Daten in einen hochdimensionalen Merkmalsraum, in dem unter Einsatz des Kernel-Tricks die lineare PCA erfolgt. Abschnitt 4.5.1 geht auf das Training des Datenmodells ein, bevor Abschnitt 4.5.2 die Anwendung zur Fehlerdetektion vorstellt. In der Literatur existiert eine Vielzahl an Kernel-Funktionen, die sich für die Transformation der Daten eignen (Abschnitt 4.5.3). Abschnitt 4.5.4 wendet diese exemplarisch auf eine zweidimensionale Verteilung basierend auf experimentellen Prüfstandsdaten an und unterscheidet lokale von globalen Kernel-Funktionen. Abschnitt 4.5.5 stellt schließlich die Anwendung auf die vollständige Datenmatrix des Prüfstands vor. Basierend darauf vergleicht Abschnitt 4.5.6 die ISC-Detektionsperformance der neuen Methode mit bekannten Methoden aus der Literatur. Für die angestrebte Anwendung des Verfahrens im automobilen Umfeld ist die Recheneffizienz der Algorithmen ein entscheidender Faktor. Abschnitt 4.5.7 geht deshalb auf die Komplexität des nichtlinearen Monitorings ein und schlägt eine effiziente Wahl an Trainingsdaten vor, die das Datenmodell bestmöglich approximiert. In einer weiteren Untersuchung geht Abschnitt 4.5.8 auf den Einfluss und eine Pareto-optimale Wahl der Kernel-Parameter ein. Abschnitt 4.5.9 erweitert den Ansatz zur ISC-Detektion um eine Fehlerisolation, basierend auf einer Beitragsanalyse der Variablen zu den Kontrollstatistiken.

### 4.5.1 Training des Datenmodells

Wie in Abschnitt 2.4.2 beschrieben, lässt sich die PCA auf multivariat Gauß-verteilte Daten effektiv anwenden. Wenn die Daten jedoch nichtlineare Variationen aufweisen, ist es immer möglich, die Daten in einen höherdimensionalen Raum zu transformieren, in dem sie linear variieren. Nach dem Coverschen Theorem sind nichtlineare Daten im Eingangsraum allgemein



**Abbildung 4.27:** Übersicht aller Schritte des KPCA-basierten Zellmonitorings zur ISC-Detektion sowie dessen Schnittstellen und Parameter.

nach einer nichtlinearen Abbildung eher linear [112, 157]. Die nichtlineare Abbildung  $\Phi(\cdot)$  in den sogenannten Merkmalsraum (*Feature-Space*)  $\mathbb{F}$  erfolgt gemäß der Abbildung

$$\Phi : \mathbb{R}^m \rightarrow \mathbb{F}, \mathbf{z} \mapsto \mathfrak{z}. \quad (4.204)$$

Die Dimension des Merkmalsraums ist  $\dim(\mathbb{F}) \gg m$  und nicht notwendigerweise endlich. Die Kernidee der KPCA besteht darin, die lineare PCA im Merkmalsraum durchzuführen, was zu einer nichtlinearen Erweiterung der PCA im Eingangsraum führt. Die von Schölkopf, Smola und Müller eingeführte Kernel-Methode erlaubt es, die KPCA durchzuführen, ohne die hochdimensionale Merkmalsraumrepräsentation der Eingabedaten tatsächlich zu berechnen [251]. Lee, Yoo u. a. haben die Methode für die datengetriebene Fehlerdiagnose angepasst und Sun, Tsung und Qu haben die optimale Wahl von Kernel-Funktionen zur Fehlerdiagnose untersucht [157, 271].

Zunächst wird angenommen, dass die Daten im Merkmalsraum zentriert sind, das heißt

$$\sum_{\tau=1}^N \Phi(\mathbf{z}_\tau) = 0. \quad (4.205)$$

Dann ist

$$\mathfrak{G} = \frac{1}{N-1} \sum_{\tau=1}^N \Phi(\mathbf{z}_\tau) \Phi(\mathbf{z}_\tau)^T \quad (4.206)$$

die Approximation der Gram-Matrix im Merkmalsraum. Wie für das lineare Monitoring erfolgt eine Eigenwertzerlegung

$$\mathfrak{G} \mathbf{p}_s = \lambda_s \mathbf{p}_s \quad (4.207)$$

von  $\mathfrak{G} \in \mathbb{R}^{N \times N}$  in  $\mathbb{F}$ . Insgesamt ergeben sich  $s \in [1, N]$  Eigenvektoren  $\mathbf{p}_s \in \mathbb{R}^N$ . So wie die Eingangsraum-Kovarianzmatrix  $\mathbf{C}$  in  $\text{span}\{\mathbf{z}_1, \dots, \mathbf{z}_N\}$  liegt, liegt die Merkmalsraum-Gram-Matrix in  $\text{span}\{\Phi(\mathbf{z}_1), \dots, \Phi(\mathbf{z}_N)\}$ . Es gibt also Vektoren  $\boldsymbol{\alpha}_s = [\alpha_{s1} \dots \alpha_{sN}]^T \in \mathbb{R}^N$ , so dass

$$\mathbf{p}_s = \sum_{j=1}^N \alpha_{sj} \Phi(\mathbf{z}_j) \quad (4.208)$$

gilt. Mit Gleichung (4.208) lässt sich (4.207) gemäß

$$\mathfrak{G} \sum_{j=1}^N \alpha_{sj} \Phi(\mathbf{z}_j) = \lambda_s \sum_{j=1}^N \alpha_{sj} \Phi(\mathbf{z}_j) \quad (4.209)$$

umformulieren. Mit (4.206) folgt für die linke Seite von (4.209)

$$\left( \frac{1}{N-1} \sum_{\tau=1}^N \Phi(\mathbf{z}_\tau) \Phi(\mathbf{z}_\tau)^T \right) \sum_{j=1}^N \alpha_{sj} \Phi(\mathbf{z}_j) = \frac{1}{N-1} \sum_{\tau=1}^N \Phi(\mathbf{z}_\tau) \left( \sum_{j=1}^N \alpha_{sj} \Phi(\mathbf{z}_\tau)^T \Phi(\mathbf{z}_j) \right). \quad (4.210)$$

Multipliziert man beide Seiten von (4.209) mit  $\Phi(\mathbf{z}_l)^T$ ,  $l \in [1, N]$  und verwendet (4.210), erhält man ein Gleichungssystem mit  $N$  Gleichungen:

$$\frac{1}{N-1} \sum_{\tau=1}^N \Phi(\mathbf{z}_l)^T \Phi(\mathbf{z}_\tau) \left( \sum_{j=1}^N \alpha_{sj} \Phi(\mathbf{z}_\tau)^T \Phi(\mathbf{z}_j) \right) = \lambda_s \sum_{\tau=1}^N \alpha_{s\tau} \Phi(\mathbf{z}_l)^T \Phi(\mathbf{z}_\tau). \quad (4.211)$$

In (4.211) erscheinen die Vektoren im Merkmalsraum nur in Form von Skalarprodukten. Die Einführung der Kernel-Funktion

$$\kappa : \mathbb{R}^m \times \mathbb{R}^m \rightarrow \mathbb{R} \quad (4.212)$$

erlaubt es, die Skalarprodukte von zwei Vektoren im Merkmalsraum durch

$$\kappa(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = \Phi(\mathbf{z}_{\tau_1})^T \Phi(\mathbf{z}_{\tau_2}) \quad (4.213)$$

zu ersetzen. Somit folgt

$$\frac{1}{N-1} \sum_{\tau=1}^N \kappa(\mathbf{z}_l, \mathbf{z}_\tau) \left( \sum_{j=1}^N \alpha_{sj} \kappa(\mathbf{z}_\tau, \mathbf{z}_j) \right) = \lambda_s \sum_{\tau=1}^N \alpha_{s\tau} \kappa(\mathbf{z}_l, \mathbf{z}_\tau) \quad (4.214)$$

für (4.211). Die Einführung der Kernel-Matrix

$$\mathbf{K} = \begin{bmatrix} \kappa(\mathbf{z}_1, \mathbf{z}_1) & \dots & \kappa(\mathbf{z}_1, \mathbf{z}_{\tau_2}) & \dots & \kappa(\mathbf{z}_1, \mathbf{z}_N) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \kappa(\mathbf{z}_{\tau_1}, \mathbf{z}_1) & \dots & \kappa(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) & \dots & \kappa(\mathbf{z}_{\tau_1}, \mathbf{z}_N) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \kappa(\mathbf{z}_N, \mathbf{z}_1) & \dots & \kappa(\mathbf{z}_N, \mathbf{z}_{\tau_2}) & \dots & \kappa(\mathbf{z}_N, \mathbf{z}_N) \end{bmatrix} \quad (4.215)$$

ermöglicht eine Matrixnotation

$$\frac{1}{N-1} \mathbf{K}^2 \boldsymbol{\alpha}_s = \lambda_s \mathbf{K} \boldsymbol{\alpha}_s. \quad (4.216)$$

Um (4.216) zu lösen, wird das Eigenwertproblem

$$\frac{1}{N-1} \mathbf{K} \boldsymbol{\alpha}_s = \lambda_s \boldsymbol{\alpha}_s \quad (4.217)$$

gelöst, da alle Lösungen von (4.217) die Beziehung (4.216) erfüllen [251]. Die Lösung von (4.217) anstelle von (4.207) erlaubt die Realisierung der PCA im Merkmalsraum  $\mathbb{F}$ , ohne dass eine explizite Berechnung der Abbildung  $\mathfrak{z} = \Phi(\mathbf{z})$  erforderlich ist. Stattdessen müssen nur die Skalarprodukte der abgebildeten Daten berechnet werden [253].

Gleichung (4.205) nimmt an, dass die Daten im Merkmalsraum zentriert sind. Um diese



Eigenschaft zu gewährleisten, wird eine Zentrierung

$$\Phi(\mathbf{z}_\tau) = \tilde{\Phi}(\mathbf{z}_\tau) - \frac{1}{N} \sum_{\tau=1}^N \tilde{\Phi}(\mathbf{z}_\tau) \quad (4.218)$$

der Daten im Merkmalsraum durchgeführt. Um eine explizite Berechnung der Abbildung  $\Phi$  zu vermeiden, erfolgt die Zentrierung unter der erneuten Anwendung des Kernel-Tricks basierend auf der nicht-zentrierten Kernel-Matrix  $\tilde{\mathbf{K}}$  (siehe Anhang A.5). Die resultierende Vorschrift zur Zentrierung der Daten in  $\mathbb{F}$  lautet:

$$\mathbf{K} = \tilde{\mathbf{K}} - \frac{1}{N} \mathbf{1}_{N \times N} \tilde{\mathbf{K}} - \frac{1}{N} \tilde{\mathbf{K}} \mathbf{1}_{N \times N} + \frac{1}{N^2} \mathbf{1}_{N \times N} \tilde{\mathbf{K}} \mathbf{1}_{N \times N}. \quad (4.219)$$

Dabei bezeichnet  $\mathbf{1}_{N \times N} \in \mathbb{R}^{N \times N}$  die Eins-Matrix mit identischen Einträgen  $(\mathbf{1}_{N \times N})_{ij} = 1$ . Für die Normierung der Eigenvektoren im Merkmalsraum gilt

$$\mathbf{1} \stackrel{!}{=} \mathbf{p}_s^T \mathbf{p}_s = \sum_{i=1}^N \sum_{j=1}^N \alpha_{si} \alpha_{sj} \Phi(\mathbf{z}_i)^T \Phi(\mathbf{z}_j) = \boldsymbol{\alpha}_s^T \mathbf{K} \boldsymbol{\alpha}_s. \quad (4.220)$$

Die Lösung des Eigenwertproblems (4.217) erfolgt mittels der Singulärwertzerlegung gemäß

$$\frac{1}{N-1} \mathbf{K} = \mathbf{S} \boldsymbol{\Lambda} \mathbf{S}^T, \quad (4.221)$$

wobei  $\mathbf{S} = [\boldsymbol{\alpha}_1 \dots \boldsymbol{\alpha}_N] \in \mathbb{R}^{N \times N}$  die Eigenvektoren und  $\boldsymbol{\Lambda} = \text{diag}(\lambda_1 \dots \lambda_N) \in \mathbb{R}^{N \times N}$  die Eigenwerte von  $\frac{1}{N-1} \mathbf{K}$  sind. Die sortierten Eigenwerte  $\lambda_1 \geq \dots \geq \lambda_\gamma \geq \dots \geq \lambda_N \geq 0$  und die zugehörigen Eigenvektoren  $\boldsymbol{\alpha}_s$  werden analog zur linearen PCA in zwei orthogonale Unterräume  $\mathbb{S}_{\text{pc}}^{\mathfrak{G}} \equiv \text{span}\{\boldsymbol{\alpha}_1, \dots, \boldsymbol{\alpha}_\gamma\}$  und  $\mathbb{S}_{\text{res}}^{\mathfrak{G}} \equiv \text{span}\{\boldsymbol{\alpha}_{\gamma+1}, \dots, \boldsymbol{\alpha}_N\}$  aufgeteilt. Die Zerlegung von  $\mathbf{S} = [\mathbf{S}_{\text{pc}} \mathbf{S}_{\text{res}}]$  in  $\mathbf{S}_{\text{pc}} \in \mathbb{R}^{N \times \gamma}$  und  $\mathbf{S}_{\text{res}} \in \mathbb{R}^{N \times (N-\gamma)}$  sowie

$$\boldsymbol{\Lambda} = \begin{bmatrix} \boldsymbol{\Lambda}_{\text{pc}} & \mathbf{0} \\ \mathbf{0} & \boldsymbol{\Lambda}_{\text{res}} \end{bmatrix} \quad (4.222)$$

in  $\boldsymbol{\Lambda}_{\text{pc}} \in \mathbb{R}^{\gamma \times \gamma}$  und  $\boldsymbol{\Lambda}_{\text{res}} \in \mathbb{R}^{(N-\gamma) \times (N-\gamma)}$  erfolgt anhand der  $\gamma$  größten Eigenwerte. Wie bei der linearen Fehlerdiagnose beschreiben die ersten  $\gamma$ -Hauptkomponenten die systematischen Variationen der Daten. Die Wahl von  $\gamma$  erfolgt unter Verwendung der CPV-Methode mit einem Schwellenwert von 99.9% für die erklärte Datenvarianz. Die Scores entlang der ersten  $\gamma$ -Eigenvektoren erhält man durch die Projektion

$$\mathbf{T}^{\text{pc}} = [\mathbf{t}_1^{\text{pc}} \dots \mathbf{t}_\gamma^{\text{pc}} \dots \mathbf{t}_N^{\text{pc}}] = \mathbf{S}_{\text{pc}}^T \mathbf{K} \in \mathbb{R}^{\gamma \times N}. \quad (4.223)$$

### 4.5.2 Fehlerdetektion

Liegen neue, zentrierte Testdaten  $\mathbf{z}_t \in \mathbb{R}^m$  vor, so ist der Kernel-Vektor bestehend aus Skalarprodukten im Merkmalsraum durch

$$\tilde{\mathbf{k}}_t = \left[ \tilde{\kappa}(\mathbf{z}_t, \mathbf{z}_1) \dots \tilde{\kappa}(\mathbf{z}_t, \mathbf{z}_\tau) \dots \tilde{\kappa}(\mathbf{z}_t, \mathbf{z}_N) \right]^T \in \mathbb{R}^N \quad (4.224)$$

gegeben, wobei  $\mathbf{z}_\tau$ ,  $\tau \in [1, N]$  die Trainingsdaten sind. Die Zentrierung von  $\tilde{\mathbf{k}}_t$  im Merkmalsraum

$$\mathbf{k}_t = \tilde{\mathbf{k}}_t - \frac{1}{N} \tilde{\mathbf{K}} \mathbf{1}_N - \frac{1}{N} \mathbf{1}_{N \times N} \tilde{\mathbf{k}}_t + \frac{1}{N^2} \mathbf{1}_{N \times N} \tilde{\mathbf{K}} \mathbf{1}_N \quad (4.225)$$

erfolgt analog zu (4.219), mit dem Eins-Vektor  $\mathbf{1}_N \in \mathbb{R}^N$ . Anhang A.5 leitet (4.225) her.

Um die lineare PCA im Merkmalsraum  $\mathbb{F}$  durchzuführen, wird der zentrierte Kernel-Vektor  $\mathbf{k}_t$  in den Haupt- und Residual-Unterraum

$$\mathbf{t}_t^{\text{pc}} = \mathbf{S}_{\text{pc}}^T \mathbf{k}_t \in \mathbb{S}_1^{\mathfrak{G}} \quad (4.226)$$

$$\mathbf{t}_t^{\text{res}} = \mathbf{S}_{\text{res}}^T \mathbf{k}_t \in \mathbb{S}_{\text{res}}^{\mathfrak{G}} \quad (4.227)$$

projiziert. Die Berechnung der beiden Statistiken

$$T^2(\mathbf{z}_t) = \mathbf{k}_t^T \mathbf{S}_{\text{pc}} \mathbf{\Lambda}_{\text{pc}}^{-1} \mathbf{S}_{\text{pc}}^T \mathbf{k}_t = (\mathbf{t}_t^{\text{pc}})^T \mathbf{\Lambda}_{\text{pc}}^{-1} \mathbf{t}_t^{\text{pc}} \quad (4.228)$$

und

$$Q(\mathbf{z}_t) = \mathbf{k}_t^T \mathbf{S}_{\text{res}} \mathbf{S}_{\text{res}}^T \mathbf{k}_t = \mathbf{k}_t^T \mathbf{k}_t - (\mathbf{t}_t^{\text{pc}})^T \mathbf{t}_t^{\text{pc}} \quad (4.229)$$

erlaubt eine Erkennung von anomalem Verhalten [157, 217]. Die UCLs ermittelt eine Kerndichteschätzung.

### 4.5.3 Wahl der Kernel-Funktionen

Gleichung (4.213) führt die Kernel-Funktion  $\kappa(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2})$  ein. Die Wahl der Kernel-Funktion ist nicht beliebig. Der Satz von Mercer liefert Bedingungen für Kernel-Funktionen, die als Skalarprodukt in einem möglicherweise  $\infty$ -dimensionalen Raum, dem Hilbertraum mit reproduzierendem Kern (Reproducing-Kernel-Hilbert-Space, RKHS), agieren können [45]. Die Anwendung zulässiger Kerne führt stets zu einer positiv semidefiniten Kernel-Matrix  $\mathbf{K}$  [217]. Die Wahl des linearen Kerns

$$\kappa_{\text{lin}}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = \mathbf{z}_{\tau_1}^T \mathbf{z}_{\tau_2} + c \quad (4.230)$$

mit Offset  $c \in \mathbb{R}$  entspricht für  $c = 0$  der linearen Version der PCA mit der Gram-Matrix anstelle der Kovarianzmatrix (siehe Abschnitt 2.4.2). Die in Abschnitt 4.5.1 vorgestellten

Anpassungen erlauben eine Erweiterung der linearen PCA auf polynomiale Kerne der Form

$$\kappa_{\text{poly}}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = (\alpha \mathbf{z}_{\tau_1}^T \mathbf{z}_{\tau_2} + \text{const})^d \quad (4.231)$$

mit dem Polynomgrad  $d$ . Für  $d \in \mathbb{N}$  erhält man zulässige Kernel-Funktionen, die die Mercer-Bedingung erfüllen. Weitere Freiheitsgrade liefern die Koeffizienten  $\alpha$  und  $c$  (siehe Abbildung 4.28). Ein weit verbreiteter Kern ist die Gaußsche radiale Basisfunktion (RBF)

$$\kappa_{\text{gauss}}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{z}_{\tau_1} - \mathbf{z}_{\tau_2}\|^2\right) \quad (4.232)$$

mit der Breite  $\sigma$ , die die Mercer-Bedingung für  $\sigma > 0$  erfüllt [45].  $\kappa_{\text{gauss}}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2})$  ergibt einen  $\infty$ -dimensionalen RKHS  $\mathbb{F}$ , da die Exponentialfunktion als Polynom unendlichen Grades betrachtet werden kann, wenn sie als Potenzreihe geschrieben wird [217]. Abbildung 4.28 zeigt eine Auswahl weiterer möglicher Kernel-Funktionen, abhängig von den Koeffizienten  $c$ ,  $d$  und  $\sigma$ . Dazu zählen der Rational-Quadratic-Kern

$$\kappa_{\text{rq}}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = 1 - \frac{\|\mathbf{z}_{\tau_1} - \mathbf{z}_{\tau_2}\|^2}{\|\mathbf{z}_{\tau_1} - \mathbf{z}_{\tau_2}\|^2 + \text{const}}, \quad (4.233)$$

der inverse Multiquadric-Kern

$$\kappa_{\text{imult}}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = \frac{1}{\sqrt{\|\mathbf{z}_{\tau_1} - \mathbf{z}_{\tau_2}\|^2 + \text{const}^2}}, \quad (4.234)$$

der Cauchy-Kern

$$\kappa_{\text{cauchy}}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = \frac{1}{1 + \frac{1}{\sigma^2} \|\mathbf{z}_{\tau_1} - \mathbf{z}_{\tau_2}\|^2} \quad (4.235)$$

und der verallgemeinerte T-Student-Kern

$$\kappa_{\text{tstud}}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = \frac{1}{1 + \|\mathbf{z}_{\tau_1} - \mathbf{z}_{\tau_2}\|^d}. \quad (4.236)$$

Nach [132] lassen sich Kernel-Funktionen in *lokale* und *globale* Funktionen einteilen. Beim linearen und polynomialen Kern handelt es sich um globale Kernel-Funktionen, die restlichen vorgestellten Kerne sind lokal. Während lokale Kernel-Funktionen eine gute Interpolationsleistung innerhalb der Trainingsdaten besitzen, zeigen sie schlechte Extrapolationseigenschaften. Dieses Verhalten untersuchen auch Pilario, Cao und Shafiee in ihrer Studie zu globalen und lokalen Kernen [217]: Sei  $\mathbf{z}_\tau \in \mathbb{R}^m$  die Trainingsdatenmenge mit  $\tau \in [1, N]$ ,  $\mathbf{z}_t^* \in \mathbb{R}^m$  ein fehlerfreies Test-Sample und  $\Delta \mathbf{z}_t \in \mathbb{R}^m$  der Betrag, um den das fehlerfreie Sample durch einen Fehler verschoben wurde, sodass das beobachtete Sample  $\mathbf{z}_t = \mathbf{z}_t^* + \Delta \mathbf{z}_t \in \mathbb{R}^m$  resultiert. Nach dem Theorem von Pilario, Cao und Shafiee konvergieren die beiden Kontrollstatistiken  $T^2$  und  $Q$  beim Training mit einem beliebigen festen Datensatz  $\mathbf{z}$  und der Wahl des Gauß-Kerns

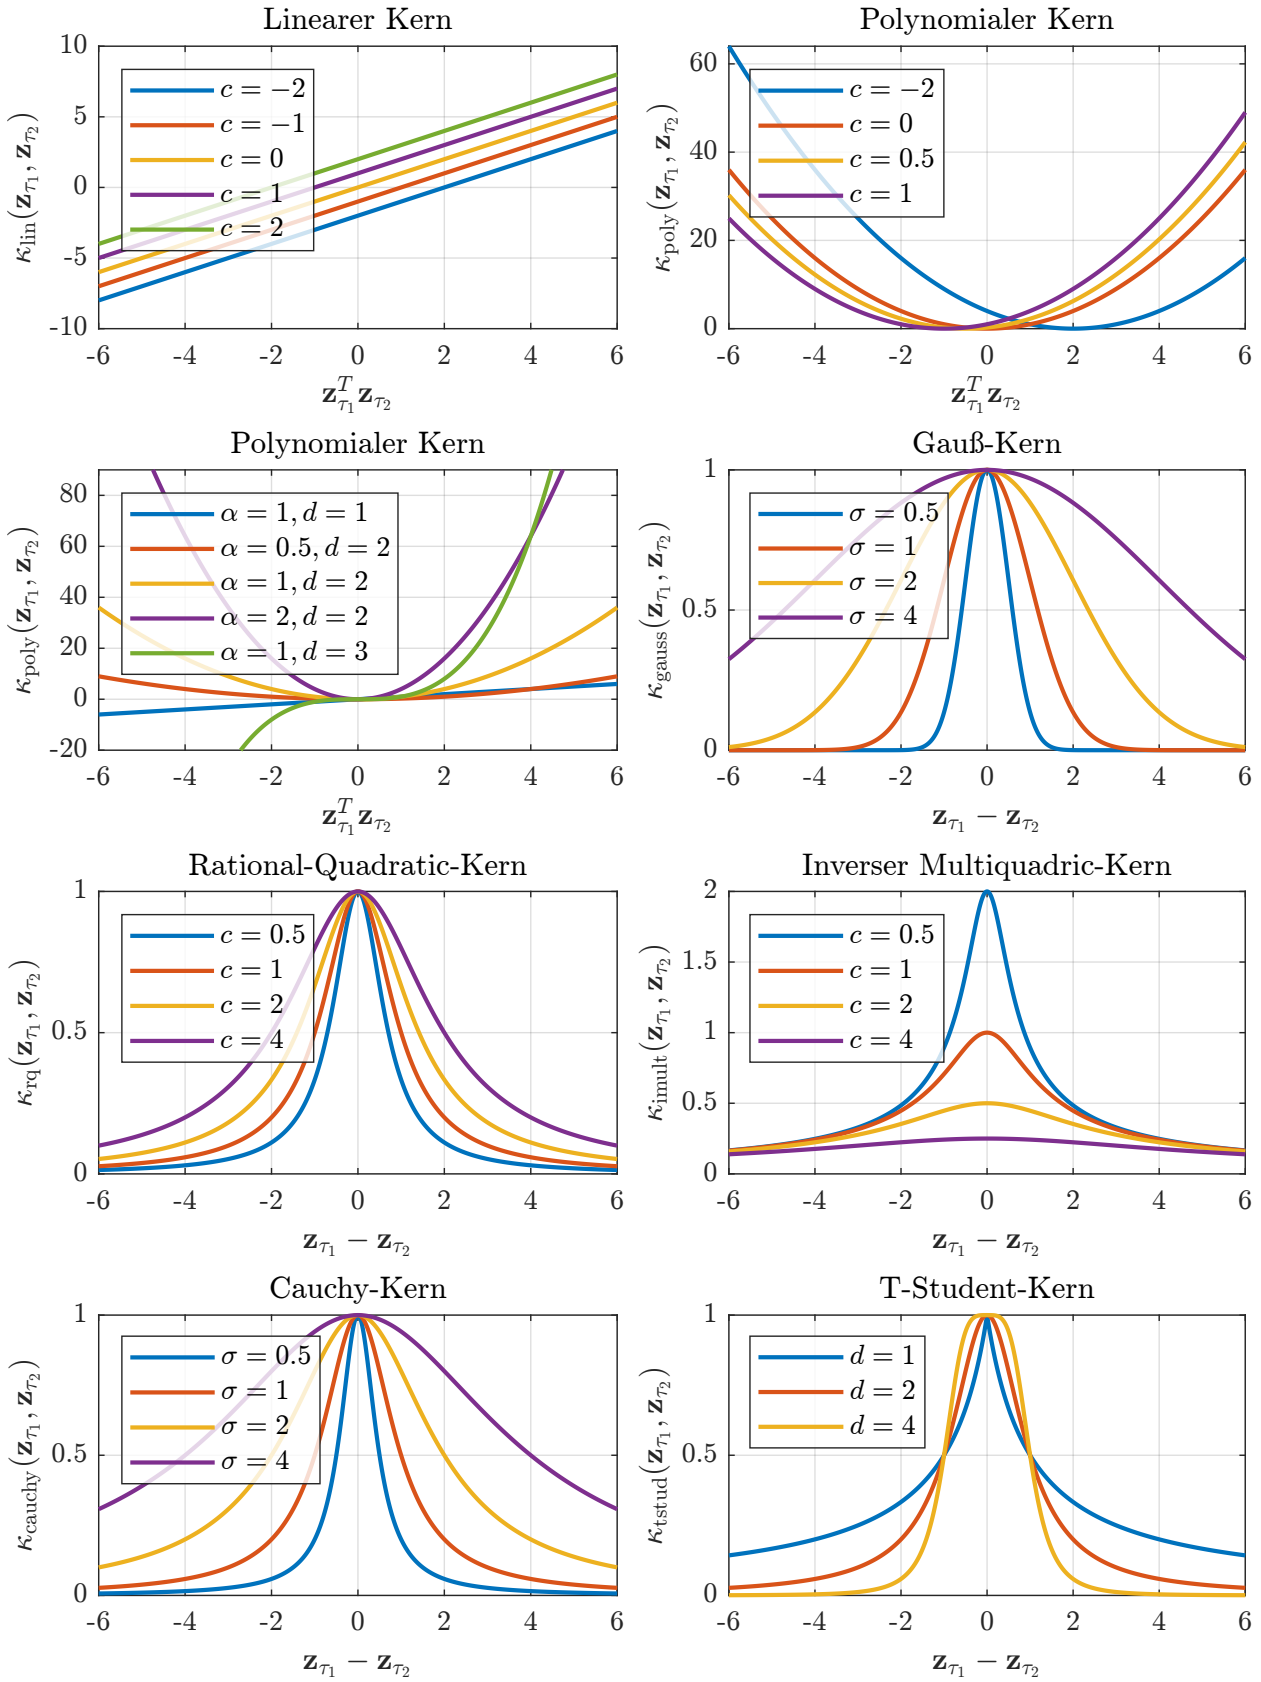


Abbildung 4.28: Häufig eingesetzte Kernel-Funktionen für verschiedene Wahlen der Koeffizienten.

mit einem konstanten  $\sigma$  gegen einen konstanten Wert für  $\|\Delta \mathbf{z}_t\| \rightarrow \infty$  [217]. Dies liegt daran, dass jedes Test-Sample für ein ausreichend großes  $\Delta \mathbf{z}_t$  immer auf den Kernel-Wert 0 projiziert wird, wenn der RBF-Kern in Gleichung (4.224) verwendet wird. Mathematisch kann dies wie folgt ausgedrückt werden [217]:

$$\lim_{\|\Delta \mathbf{z}_t\| \rightarrow \infty} \tilde{\mathbf{k}}_t = \lim_{\|\Delta \mathbf{z}_t\| \rightarrow \infty} [\tilde{k}_{\text{gauss}}(\mathbf{z}_t^* + \Delta \mathbf{z}_t, \mathbf{z}_\tau)]_{\tau \in [1, N]} = \mathbf{0} \quad \forall \tau. \quad (4.237)$$

Gleichung (4.237) resultiert direkt aus der Exponentialfunktion in (4.232) mit einem beliebigen aber festen  $\sigma$ . Mit (4.225) folgt

$$\lim_{\|\Delta \mathbf{z}_t\| \rightarrow \infty} \mathbf{k}_t = -\frac{1}{N} \tilde{\mathbf{K}} \mathbf{1}_N + \frac{1}{N^2} \mathbf{1}_{N \times N} \tilde{\mathbf{K}} \mathbf{1}_N \quad (4.238)$$

$$= \frac{1}{N^2} (\mathbf{1}_{N \times N} - N \mathbf{I}) \tilde{\mathbf{K}} \mathbf{1}_N \in \mathbb{R}^N, \quad (4.239)$$

sodass

$$\lim_{\|\Delta \mathbf{z}_t\| \rightarrow \infty} \mathbf{t}_t^{\text{pc}} = \frac{1}{N^2} \mathbf{S}_{\text{pc}}^T (\mathbf{1}_{N \times N} - N \mathbf{I}) \tilde{\mathbf{K}} \mathbf{1}_N \quad (4.240)$$

gilt. Damit folgt für die beiden Test-Statistiken

$$\lim_{\|\Delta \mathbf{z}_t\| \rightarrow \infty} T^2(\mathbf{z}_t^* + \Delta \mathbf{z}_t) = \frac{1}{N^4} \mathbf{1}_N^T \tilde{\mathbf{K}}^T (\mathbf{1}_{N \times N}^T - N \mathbf{I}) \mathbf{S}_{\text{pc}} \mathbf{\Lambda}_{\text{pc}}^{-1} \mathbf{S}_{\text{pc}}^T (\mathbf{1}_{N \times N} - N \mathbf{I}) \tilde{\mathbf{K}} \mathbf{1}_N \quad (4.241)$$

und

$$\lim_{\|\Delta \mathbf{z}_t\| \rightarrow \infty} Q(\mathbf{z}_t^* + \Delta \mathbf{z}_t) = \frac{1}{N^4} \mathbf{1}_N^T \tilde{\mathbf{K}}^T (\mathbf{1}_{N \times N}^T - N \mathbf{I}) (\mathbf{I} - \mathbf{S}_{\text{pc}} \mathbf{S}_{\text{pc}}^T) (\mathbf{1}_{N \times N} - N \mathbf{I}) \tilde{\mathbf{K}} \mathbf{1}_N. \quad (4.242)$$

Das heißt, die Statistiken konvergieren für große  $\Delta \mathbf{z}_t$  stets gegen einen konstanten Wert, der nur von den Trainingsdaten und dem Kernel-Parameter  $\sigma$  abhängt. Dieses Verhalten lässt sich auch geometrisch interpretieren. Da lokale Kerne für große  $\|\mathbf{z}_{\tau_1} - \mathbf{z}_{\tau_2}\|$  gegen Null tendieren, sind die transformierten Datenpunkte nach der Abbildung in den Merkmalsraum nicht mehr trennbar. Gerade für die Detektion von ISCs ist dies jedoch ein unerwünschtes Verhalten. Mit fortschreitendem Bestehen des ISCs ist aufgrund der steigenden Spannungsdifferenz ein signifikanter Anstieg von  $\Delta \mathbf{z}_t$  zu beobachten, was aufgrund des lokalen Kerns zu konstanten Werten in den Kontrollstatistiken führt. Abhilfe dafür kann zwar ein größeres  $\sigma$  schaffen, wodurch jedoch die Sensitivität auf beginnende Fehler in einer frühen ISC-Phase sinkt. Darüber hinaus gibt es keine Garantie, dass die konstanten Werte aus (4.241) und (4.242) über den UCLs liegen, sodass selbst mit fortschreitendem Bestehen des ISCs und einer steigenden Spannungsdifferenz die Beobachtungen als fehlerfrei gewertet werden. Der nächste Abschnitt 4.5.4 verdeutlicht dieses Verhalten am Beispiel experimenteller Daten. Die Wahl der Kernel-Parameter ist für lokale Kerne daher immer ein Kompromiss zwischen guter

Interpolation und ausreichender Extrapolation.

Betrachtet man hingegen globale Kernel-Funktionen, wie im Allgemeinen den polynomialen Kern aus Gleichung (4.231), der auch den linearen Kern beinhaltet, so gilt [217]:

$$\lim_{\|\Delta \mathbf{z}_t\| \rightarrow \infty} \tilde{\mathbf{k}}_t = \lim_{\|\Delta \mathbf{z}_t\| \rightarrow \infty} [\tilde{\kappa}_{\text{poly}}(\mathbf{z}_t^* + \Delta \mathbf{z}_t, \mathbf{z}_\tau)]_{\tau \in [1, N]} = \pm \infty \quad \forall \tau \quad (4.243)$$

für ein beliebiges aber festes  $c$ . Das Vorzeichen von (4.243) hängt vom Polynomgrad  $d$  und der Richtung von  $\Delta \mathbf{z}_t$  ab. Daraus folgt direkt

$$\lim_{\|\Delta \mathbf{z}_t\| \rightarrow \infty} T^2(\mathbf{z}_t^* + \Delta \mathbf{z}_t) = \infty \quad (4.244)$$

und

$$\lim_{\|\Delta \mathbf{z}_t\| \rightarrow \infty} Q(\mathbf{z}_t^* + \Delta \mathbf{z}_t) = \infty. \quad (4.245)$$

Fortschreitende Fehler mit  $\|\Delta \mathbf{z}_t\| \rightarrow \infty$  führen also dazu, dass die endlichen UCLs, basierend auf den Trainingsdaten, garantiert überschritten werden.

Wie diese Untersuchung zeigt, besitzen globale Kernel-Funktionen ein gutes Extrapolationsverhalten, jedoch ein schlechteres Interpolationsverhalten als lokale Kerne. Für die Anwendung zur ISC-Detektion ist es jedoch das Ziel, sowohl empfindlich auf Soft-ISCs zu reagieren, bei denen ein lokale Kernel-Funktion vorteilhaft ist, aber dennoch robust bei fortgeschrittenen ISCs zu sein, die große  $\|\Delta \mathbf{z}_t\|$ , beziehungsweise große Abstände zwischen fehlerhaften Testdaten und Trainingsdaten  $\|\mathbf{z}_t - \mathbf{z}_\tau\|$  verursachen. Durch die Kombination von lokalen und globalen Kernen lassen sich gleichzeitig ein gutes Extrapolations- und Interpolationsverhalten erzielen [217]. Die Kombination der Kerne zu einem gemischten Kern erfolgt gemäß

$$\kappa_{\text{mix}}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = \sum_{l=1}^{N_{\text{ker}}} \omega_l \kappa_l(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) \quad (4.246)$$

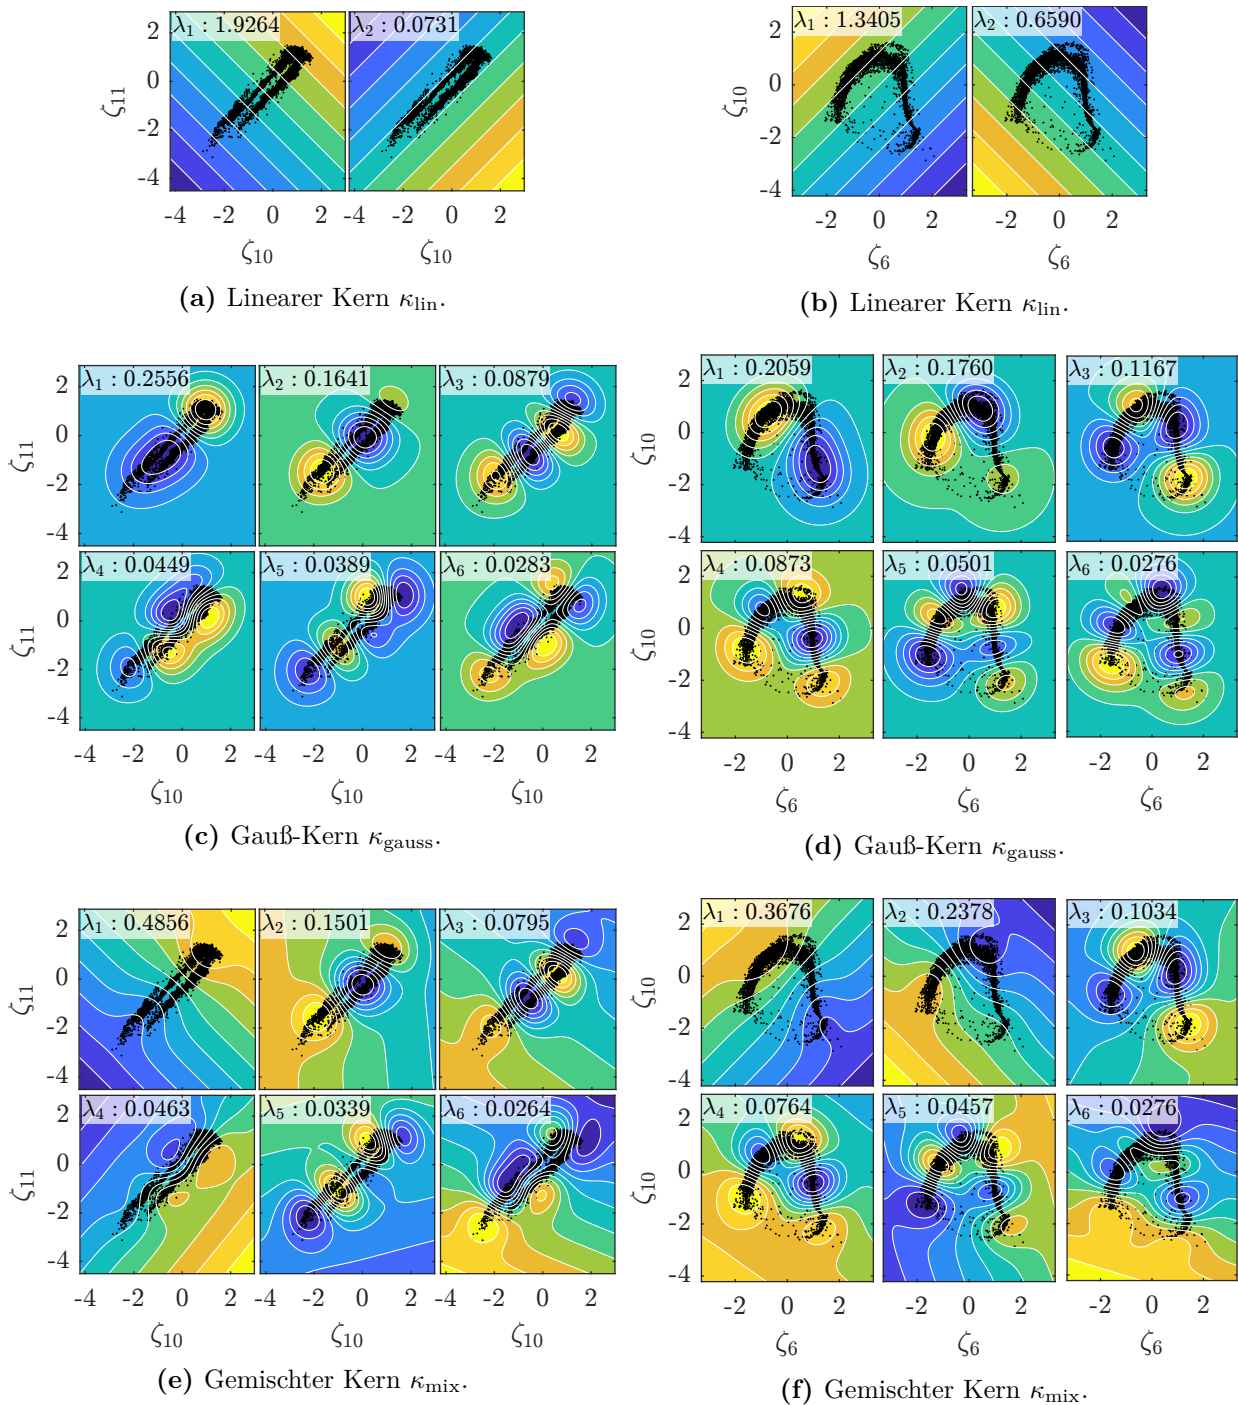
mit  $\sum_{l=1}^{N_{\text{ker}}} \omega_l \stackrel{!}{=} 1$ .

#### 4.5.4 Einfluss lokaler und globaler Kernel-Funktionen

Nachfolgend soll der Einfluss lokaler, globaler und gemischter Kerne sowie deren Interpolations- und Extrapolationseigenschaften untersucht werden. Zudem erfolgt ein Vergleich des linearen PCA-basierten Monitorings mit dem nichtlinearen KPCA-Verfahren. Zur besseren Visualisierung erfolgt die Untersuchung anhand eines zweidimensionalen Datensatzes. Dafür kommen aufgrund ihrer größeren Parametervariationen die PAN-Daten zum Einsatz. Der Widerstand des emulierten ISCs an Zelle 10 beträgt  $100 \Omega$ . Der hochohmige Kurzschluss erlaubt es, die Sensitivität der Methoden für beginnende Fehler zu untersuchen. Um die PCA und die KPCA gegenüberzustellen, werden die annähernd linear variierenden Zellen 10 und 11

sowie die stark nichtlinear variierenden Zellen 6 und 10 gewählt (siehe Abbildung 4.19). Die Hinzunahme von Zelle 10 in beiden Fällen ermöglicht es, den Fehlerfall zu analysieren. Der nahezu lineare Zusammenhang der Zellen 10 und 11 lässt sich durch ihre ähnlichen Parameter erklären. Sie besitzen vergleichbare Kapazitäten von  $Q_{10} = 21.93 \text{ Ah}$  und  $Q_{11} = 21.82 \text{ Ah}$  (siehe Tabelle 4.1) sowie ähnliche Innenwiderstände von  $R_{10} = 1.154 \text{ m}\Omega$  und  $R_{11} = 1.175 \text{ m}\Omega$  bei  $25^\circ\text{C}$  und  $50\%$  SOC (siehe Abbildung 4.3). Die stark nichtlineare Beziehung der Zellen 6 und 10 lässt sich umgekehrt auf größerer Parameterunterschiede von  $Q_{10} = 21.93 \text{ Ah}$  und  $Q_6 = 21.19 \text{ Ah}$  (siehe Tabelle 4.1) sowie  $R_{10} = 1.154 \text{ m}\Omega$  und  $R_6 = 1.302 \text{ m}\Omega$  bei  $25^\circ\text{C}$  und  $50\%$  SOC (siehe Abbildung 4.3) zurückführen.

Abbildungen 4.29a,c,e zeigen in schwarz die fehlerfreien Trainingsdaten für den Fall  $\zeta_{10}$  und  $\zeta_{11}$  und Abbildungen 4.29b,d,f für den Fall  $\zeta_6$  und  $\zeta_{10}$ . In Farbe sind die Konturlinien der ersten zwei beziehungsweise sechs Hauptkomponenten für verschiedene Kernel-Funktionen dargestellt. Die Konturlinien entsprechen konstanten Werten entlang der Hauptkomponenten. In den Abbildungen 4.29a,b wurde der lineare Kern  $\kappa_{\text{lin}}$  gewählt, in Abbildung 4.29c,d der Gauß-Kern und in Abbildung 4.29e,f der gemischte Kern, bestehend aus einer Kombination des linearen Kerns mit dem Gauß-Kern. Die gewählten Parameter für das gewählte Beispiel betragen:  $c = 0$ ,  $\sigma = 1/\sqrt{2}$ ,  $\omega_{\text{gauss}} = 1 - \omega_{\text{lin}} = 0.85$ . Auf die optimale Wahl dieser Parameter geht Abschnitt 4.5.8 detailliert ein. In Abbildung 4.29 ist deutlich die annähernd lineare Beziehung der vorverarbeiteten Daten der Zellen 10 und 11 sowie der, durch die starken Parameterunterschiede begründete, nichtlineare Zusammenhang von  $\zeta_6$  und  $\zeta_{10}$  erkennbar. Wie aus Abschnitt 2.4.2 bekannt, entspricht der Einsatz des linearen Kerns der linearen PCA unter Verwendung der Gram-Matrix. Da  $\text{span}\{\zeta_{10}, \zeta_{11}\} = \text{span}\{\zeta_6, \zeta_{10}\} = 2$  und die Hauptkomponenten orthogonal sind, existieren nur zwei Eigenvektoren. Die erste Hauptkomponente zeigt in die Richtung der größten Varianz in den Daten, die Konturen verlaufen orthogonal zu ihr. Während der erste Eigenvektor in Abbildung 4.29a klar in Richtung der größten Datenvarianz orientiert ist, ist die Richtung im nichtlinearen Fall (Abbildung 4.29b) weniger intuitiv. Die zugehörigen Eigenwerte bestätigen diese Beobachtung. Der erste Eigenwert repräsentiert im annähernd linearen Fall bereits  $\lambda_1 / \sum_{i=1}^2 \lambda_i \approx 96\%$  der Datenvarianz, im nichtlinearen Fall jedoch nur  $\lambda_1 / \sum_{i=1}^2 \lambda_i \approx 67\%$ . Abbildungen 4.29c,d zeigen die ersten sechs Hauptkomponenten für den Gauß-Kern  $\kappa_{\text{gauss}}$ . Das gute Interpolationsverhalten des Gauß-Kerns innerhalb der Trainingsdaten ist an der hohen Dichte der Konturlinien zu erkennen; sowohl für die Zellen 10 und 11 als auch für die Zellen 6 und 10. Allerdings haben die Basisfunktionen einen kleinen Gradienten für Testdaten  $\mathbf{z}_t$ , die einen großen Abstand  $\|\mathbf{z}_t - \mathbf{z}_\tau\|$  zu den Trainingsdaten  $\mathbf{z}_\tau$  aufweisen. Wie im vorangegangenen Abschnitt 4.5.3 angeführt, würde dieser Wert im nicht-zentrierten Fall für  $\|\mathbf{z}_t - \mathbf{z}_\tau\| \rightarrow \infty$  gegen 0 konvergieren. Nach der Zentrierung gemäß den Gleichungen (4.219) beziehungsweise (4.225) ist jedoch, wie in Gleichung (4.240) gezeigt, eine Konvergenz der Konturlinien gegen einen konstanten Wert zu beobachten. Dies ist in den Abbildungen 4.29c,d an den unterschiedlichen Farben am Rand der Abbildungen zu erkennen. Testdaten  $\mathbf{z}_t$  mit einem großen Abstand zu  $\mathbf{z}_\tau$  sind in



**Abbildung 4.29:** Konturlinien der ersten zwei (a, b) und der ersten sechs (c, d, e, f) Kernel-Hauptkomponenten für die Datenvektoren  $\zeta_{10}$  und  $\zeta_{11}$ . Gewählte Parameter:  $c = 0$ ,  $\sigma = 1/\sqrt{2}$ ,  $\omega_{\text{gauss}} = 1 - \omega_{\text{lin}} = 0.85$ .

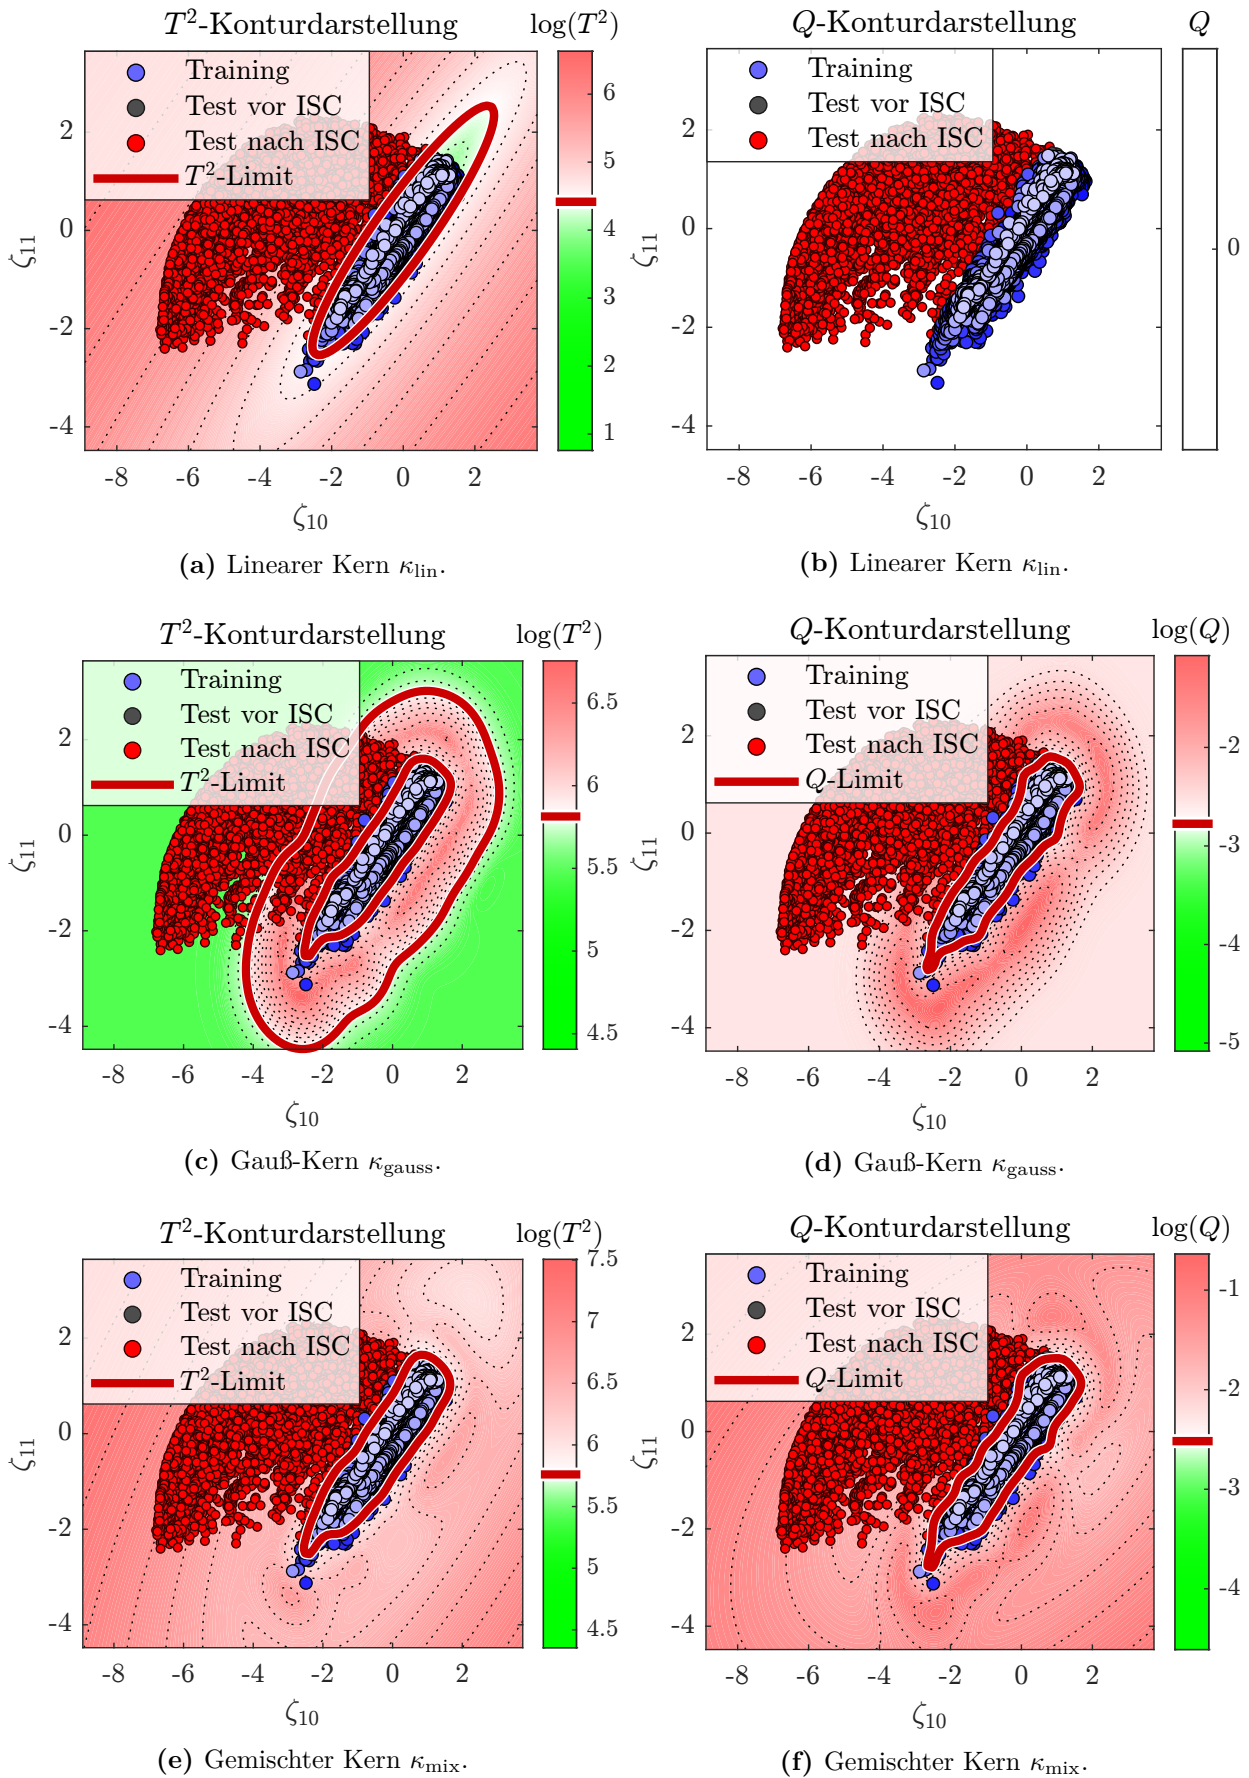


diesem Bereich kaum separierbar. Auch die Kontrollstatistiken nehmen gemäß den Gleichungen (4.241) und (4.242) konstante Werte an, was einem schlechten Extrapolationsverhalten entspricht. Der in den Abbildungen 4.29e,f gezeigte gemischte Kern kombiniert die Stärken der ersten beiden Kernel-Funktionen. Er besitzt eine erhöhte Konturliniendichte, die sich an die Verteilung der Daten anpasst. Zugleich ist aber auch ein Gradient für  $\|\mathbf{z}_t - \mathbf{z}_\tau\| \rightarrow \infty$  vorhanden. Die Kombination des globalen und des lokalen Kerns ermöglicht somit gleichzeitig gute Interpolations- und Extrapolationseigenschaften.

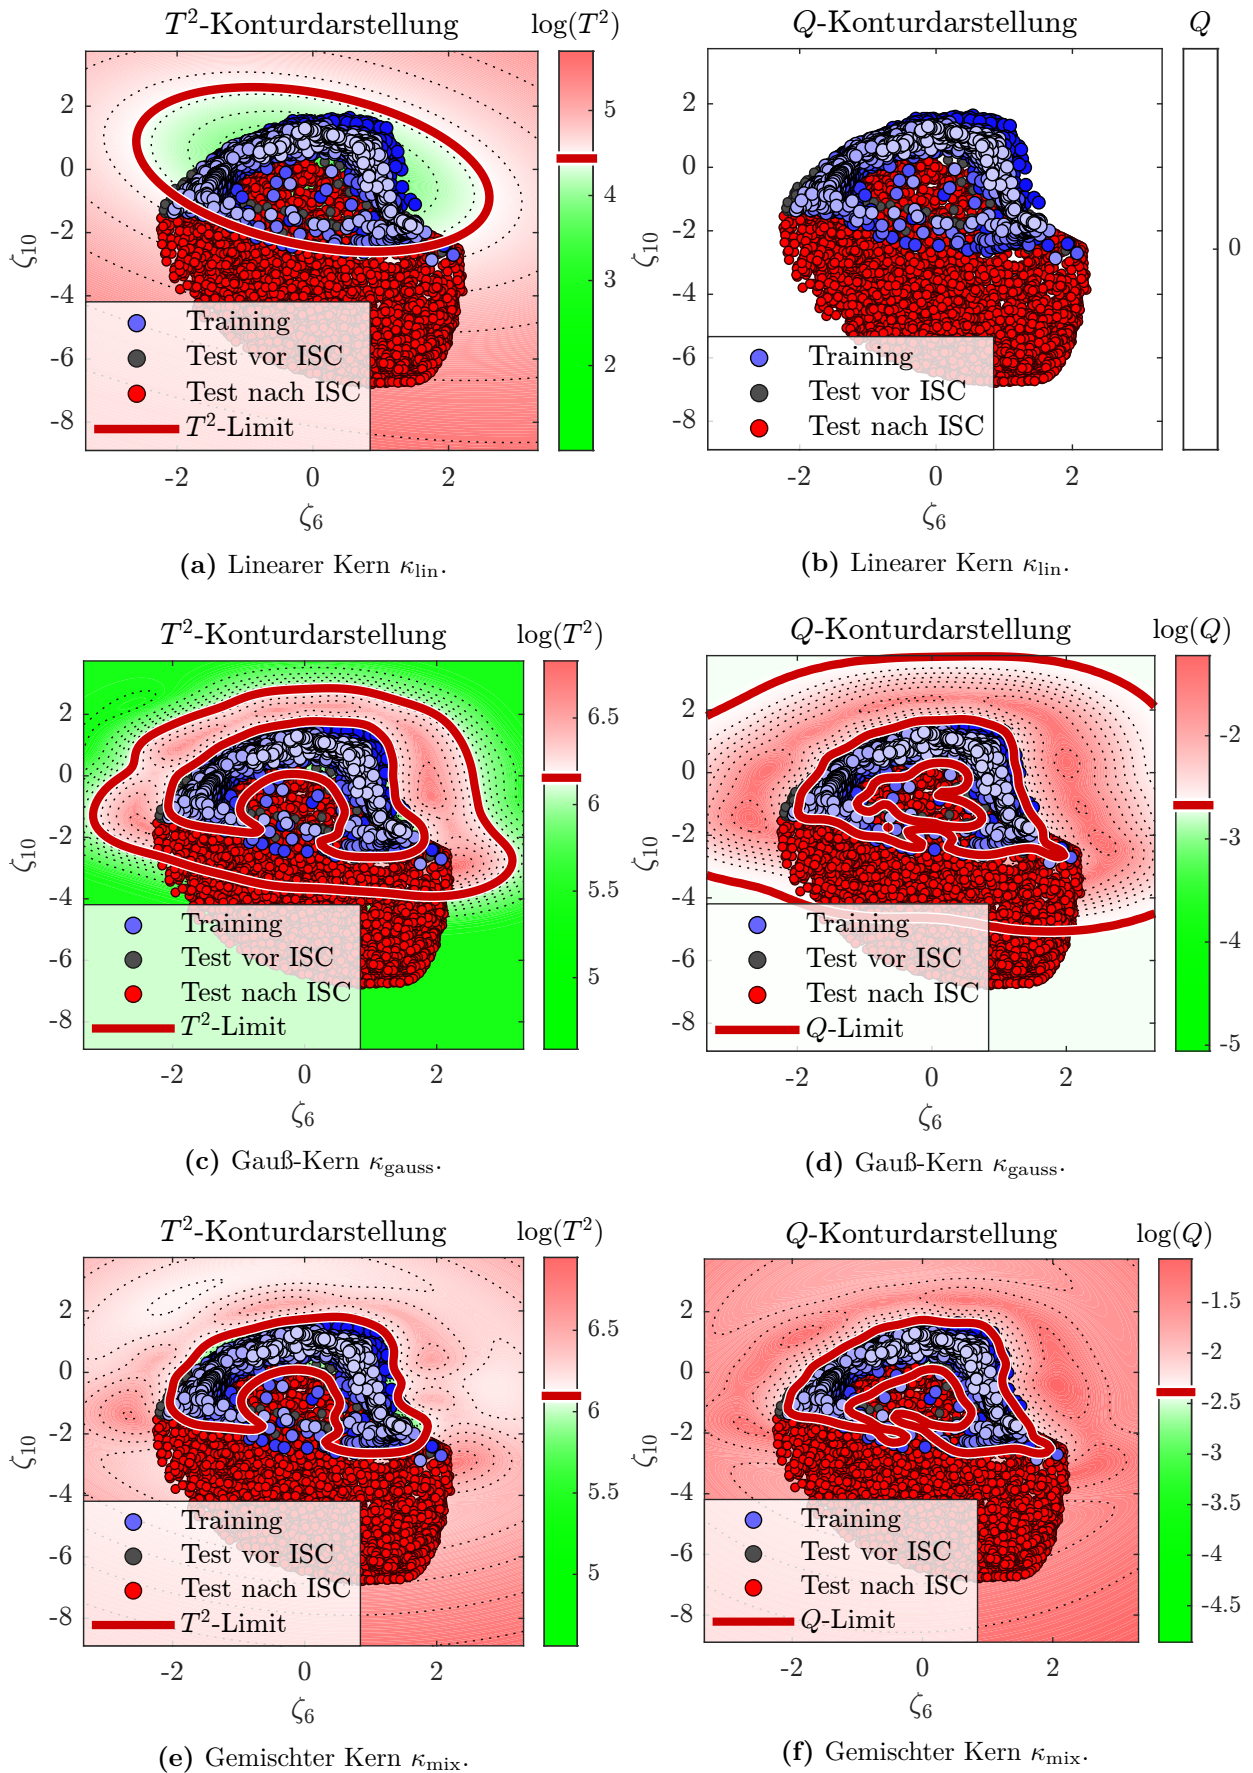
Basierend auf den in Abbildung 4.29 gezeigten Datenmodellen werden gemäß den Gleichungen (4.167) und (4.168) sowie (4.228) und (4.229) die Teststatistiken für die Online-Überwachung berechnet. Abbildung 4.30 zeigt eine Konturdarstellung der  $T^2$ - und  $Q$ -Statistiken für den linearen, Gauß- und gemischten Kern für den  $\zeta_{10}$ - $\zeta_{11}$ -Fall. Abbildung 4.31 ergänzt den  $\zeta_6$ - $\zeta_{10}$ -Fall. Die Trainingsdaten sind zeitlich sortiert in Blautönen dargestellt. Dunkelblau entspricht dem ersten, hellblau dem letzten Sample. Die Testdaten vor Auftreten des ISCs sind in grau und die Testdaten nach Auftreten des ISCs in rot markiert. Das UCL, das mit Hilfe der Kerndichteschätzung auf Basis einer Konfidenz von 99 % geschätzt wurde, ist mit einer roten Linie markiert. Für die lineare PCA (Abbildung 4.31a) entspricht die Teststatistik  $T^2$  dem Mahalanobis-Abstand zum Ursprung, so dass die Konturen immer konzentrischen Ellipsen um das Datenzentrum entsprechen (siehe Abschnitt 2.4.3). Wie in Abschnitt 4.4.1 erläutert, ermittelt das CPV-Verfahren die Anzahl der Hauptkomponenten. Die resultierenden  $\beta = 2$  Hauptkomponenten spannen jedoch bereits den vollen  $m = 2$ -dimensionalen Raum auf, weshalb

$$\mathbf{P}_{\text{pc}} \mathbf{P}_{\text{pc}}^T \Big|_{\beta=m} = \mathbf{I} \quad (4.247)$$

und nach (4.168)  $Q_i = 0, \forall \mathbf{z}_i$  folgt. Auch wenn die Teststatistik  $Q$  im Fall der zweidimensionalen Teilmenge  $\{\zeta_{10}, \zeta_{11}\}$  beziehungsweise  $\{\zeta_6, \zeta_{10}\}$  nicht zur Kontrolle geeignet ist, ist dies für höherdimensionale Daten kein Hindernis (siehe Abschnitt 4.4.2). Für die 12-dimensionalen Daten folgt beispielsweise  $\beta = 9$ . Sind die Daten annähernd Gauß-verteilt, zeigt die lineare Überwachung bereits eine hohe Sensitivität für die Erkennung von Fehlern. Je mehr die Verteilung jedoch von einer Gauß-Verteilung abweicht, desto geringer ist die Empfindlichkeit der linearen Überwachung für schleichende Fehler wie Soft-ISCs. Betrachtet man Abbildung 4.31a so werden weiter fortgeschrittene ISCs, die einen größeren Abstand  $\|\mathbf{z}_t - \mathbf{z}_\tau\|$  aufweisen zwar zuverlässig detektiert, allerdings ist die Sensitivität gegenüber kleineren Fehlern mit geringerem Abstand niedrig, da die Annahme von unabhängig Gauß-verteilten Daten hier nicht gegeben ist. Wird der Gauß-Kern verwendet (Abbildungen 4.30c,d und 4.31c,d), spiegelt die Überwachungsstatistik die Datenverteilung sehr gut wider, was eine hohe Empfindlichkeit gegenüber schleichenden Fehlern verspricht. Das gute Interpolationsverhalten ist für beide Datensätze und beide Kontrollstatistiken zu beobachten. Für Testdaten, die einen großen Abstand  $\|\mathbf{z}_t - \mathbf{z}_\tau\|$  zu den Trainingsdaten aufweisen, konvergieren die beiden Teststatistiken jedoch auf einen konstanten Wert. Dies ist auf den kleinen Gradienten der Basisfunktionen



**Abbildung 4.30:** Konturdarstellung der  $T^2$ - und  $Q$ -Kontrollstatistik in der  $\zeta_{10}\zeta_{11}$ -Ebene für die verschiedenen Kernel-Funktionen aus Abbildung 4.29.



**Abbildung 4.31:** Konturdarstellung der  $T^2$ - und  $Q$ -Kontrollstatistik in der  $\zeta_6\zeta_{10}$ -Ebene für verschiedene Kernel-Funktionen.

für  $\|\mathbf{z}_t - \mathbf{z}_\tau\|$  zurückzuführen (siehe Abbildungen 4.29c,d), wodurch die abgebildeten Punkte im Merkmalsraum kaum trennbar sind. Abschnitt 4.5.3 liefert die mathematische Grundlage für diese grafische Interpretation. Dies hat zur Folge, dass die Statistik für Testdaten mit großem Abstand zu den Trainingsdaten sogar unterhalb des UCLs liegen kann. Im gewählten Beispiel ist dies der Fall für die  $T^2$ -Statistik (Abbildung 4.30c). Im Fall der  $Q$ -Statistik liegen die weiter entfernten Testdaten oberhalb des Schwellenwertes. Allerdings hängt eine korrekte Entscheidung für beide Statistiken von der Wahl der UCLs ab, was ein unerwünschtes Verhalten ist. Größere Fehler, wie sie bei der fortschreitenden Existenz des ISCs zu beobachten sind, können fälschlicherweise als fehlerfrei gewertet werden. Der gemischte Kern  $\kappa_{\text{mix}}$  in den Abbildungen 4.30e,f und 4.31e,f kombiniert die Vorteile der ersten beiden Kernel-Funktionen. Das lokale Verhalten entspricht dem Gauß-Kern und das globale Verhalten, in Form von konzentrischen Ellipsen, dem linearen Kern. An der Überwachung von Batteriezellen zur ISC-Detektion sollte deshalb immer ein globaler Kern beteiligt sein. Dies gilt auch im Falle einer Mischung nach Gleichung (4.246), um robustes Verhalten für große Fehler zu garantieren. Andernfalls besteht mit zunehmender Fehleramplitude die Gefahr einer Fehldiagnose.

#### 4.5.5 Anwendung auf das vollständige PAN-Batteriemodul

Nach der Analyse der Methode anhand zwei exemplarischer Zellen erfolgt in diesem Abschnitt eine Anwendung auf das PAN-Batteriemodul aus Abschnitt 4.2.2 mit der vollständigen Datenmatrix  $\mathbf{Z}$ . Die Hyperparameter  $\sigma = 15.1$ ,  $\omega_{\text{gauss}} = 1 - \omega_{\text{lin}} = 0.12$  und  $\gamma = 46$  werden durch eine Partikelschwarmoptimierung identifiziert. Abschnitt 4.5.8 geht gesondert auf die Wahl der Hyperparameter ein.

Wie bei der Prozessüberwachung üblich, definiert auch diese Arbeit einige Maße, um die Detektionsleistung verschiedener Methoden zu vergleichen [59, 219]. Sei  $N_{\text{train}}^{\text{normal}}$  die Anzahl der (fehlerfreien) Trainingssamples,  $N_{\text{test}}^{\text{normal}}$  die Anzahl der fehlerfreien Testsamples und  $N_{\text{test}}^{\text{ISC}}$  die Anzahl der fehlerhaften Testsamples. Dann ist die FAR im Training gemäß

$$\text{FAR}_{\text{train}} = \frac{|T^2(\mathbf{z}_\tau) > T_{\text{UCL}}^2 \wedge Q(\mathbf{z}_\tau) > Q_{\text{UCL}}|}{N_{\text{train}}^{\text{normal}}}, \tau \in [1, N_{\text{train}}^{\text{normal}}] \quad (4.248)$$

und im Test gemäß

$$\text{FAR}_{\text{test}} = \frac{|T^2(\mathbf{z}_t) > T_{\text{UCL}}^2 \wedge Q(\mathbf{z}_t) > Q_{\text{UCL}}|}{N_{\text{test}}^{\text{normal}}}, t \in [1, N_{\text{test}}^{\text{normal}}] \quad (4.249)$$

definiert, wobei  $\wedge$  für die logische *UND*-Verknüpfung steht. Für einen Fehlalarm müssen beide Statistiken  $T^2(\mathbf{z}_t)$  und  $Q(\mathbf{z}_t)$  gleichzeitig ihren UCL-Schwellenwert überschreiten. Ähnlich verhält es sich mit der Rate der verpassten Fehler (Missed-Detection-Rate, MDR),



$$\text{MDR}_{\Delta t} = \frac{|T^2(\mathbf{z}_t) < T_{\text{UCL}}^2 \vee Q(\mathbf{z}_t) < Q_{\text{UCL}}|}{N_{\text{test}}^{\text{ISC}}}, t \in [1, N_{\text{test}}^{\text{ISC}}], \quad (4.250)$$

**Tabelle 4.4:** Zusammenfassung der Ergebnisse des KPCA-basierten Monitorings für die Fälle  $R_{\text{ISC}} = 10 \Omega$  und  $R_{\text{ISC}} = 100 \Omega$  sowie den linearen und den gemischten Kern.

$R_{\text{ISC}}$	Kern	DT	$\text{FAR}_{\text{train}}$	$\text{FAR}_{\text{test}}$	$\text{MDR}_{19\text{h}}$	$\text{MDR}_{35\text{h}}$
10 $\Omega$	$\kappa_{\text{lin}}$	0.37 h	0.23 %	0.05 %	5.00 %	
	$\kappa_{\text{mix}}$	0.31 h	0.20 %	0.05 %	0.15 %	
100 $\Omega$	$\kappa_{\text{lin}}$	5.63 h	0.20 %	0.05 %		21.57 %
	$\kappa_{\text{mix}}$	2.51 h	0.58 %	0.23 %		7.79 %

wobei  $\vee$  für die logische *ODER*-Verknüpfung steht. Die MDR beziffert die Anzahl der fehlerhaften Samples, die das Verfahren nicht als fehlerhaft erkennt. Eine verpasste Erkennung tritt auf, wenn eine der Statistiken ihr UCL nicht überschreitet, während ein Fehler vorhanden ist. Da die Testzeiträume nach Auftreten des ISCs unterschiedlich lang sind, gibt der Index  $\Delta t$  an, auf welchen Zeitraum sich die MDR bezieht. Die unterschiedlich langen Zeiträume nach Auftreten des ISCs resultieren aus den verwendeten Kurzschlusswiderständen  $R_{\text{ISC}}$ , die sich um einige Größenordnungen unterscheiden. Während bei großen Widerständen der ISC möglicherweise noch nicht detektiert ist, kann die fehlerhafte Zelle im Falle eines niederohmigen ISCs bereits unter ihre untere Cut-Off-Spannung entladen sein. Zur Bestimmung der DT wird für jede der Statistiken  $T^2$  und  $Q$  ein Erkennungsmaß gebildet, das den Wert 1 annimmt, wenn die jeweilige Statistik über dem UCL-Schwellenwert liegt und andernfalls 0 ist. Ein gleitender Mittelwert, mit einer Fenstergröße von  $t_w = 200$  Samples, erhöht die Robustheit der Überwachung.

Die Abbildungen 4.32a und 4.33 zeigen die  $T^2$ - und  $Q$ -Statistiken unter Verwendung des linearen Kerns und des gemischten Kerns für den Fall  $R_{\text{ISC}} = 10 \Omega$ . Die Kontrollstatistiken für den Fall  $R_{\text{ISC}} = 100 \Omega$  ergänzen die Abbildungen 4.34 (linearer Kern) und 4.35 (gemischter Kern). Die Trainingsdaten sind jeweils in blau, die Testdaten in rot und die UCLs, basierend auf der Kerndichteschätzung, als durchgezogene Linie dargestellt. Die Abbildungen zeigen zudem die definierten Maße  $\text{FAR}_{\text{train}}$ ,  $\text{FAR}_{\text{test}}$ ,  $\text{MDR}_{19\text{h}}$  beziehungsweise  $\text{MDR}_{35\text{h}}$  sowie die DTs. Zur besseren Übersicht fasst Tabelle 4.4 die Ergebnisse ergänzend zusammen. Exemplarisch zeigt die Abbildung 4.32b in Schwarz die resultierenden Detektionsmaße der  $T^2$  und  $Q$ -Statistik für den Fall  $R_{\text{ISC}} = 10 \Omega$  unter Verwendung des linearen Kerns. Ein Indikator für den Fehler ist in Rot dargestellt. Anhand der Abbildung lässt sich die Ermittlung der DT graphisch nachvollziehen. Die Zeitdifferenz zwischen dem Auftreten des ISCs und dem Zeitpunkt, an dem beide Statistiken die Detektionsschwelle  $d_{\text{th}} = 0.5$  überschreiten, ist als DT (blau) definiert. Das Verfahren erkennt den ISC-Fehler in allen Fällen nach der Zeit DT. Da die Fehleramplitude durch die wachsende Spannungsdifferenz zwischen den Zellen zunimmt, verursacht vor allem die Zeit zwischen dem Auftreten und der Erkennung des Fehlers die MDR. Aus diesem Grund korreliert die MDR mit der DT. Auch wenn der  $\text{FAR}_{\text{train}}$  für beide Statistiken auf 1 % definiert ist, ist die tatsächliche  $\text{FAR}_{\text{train}}$  beider Statistiken zusammen

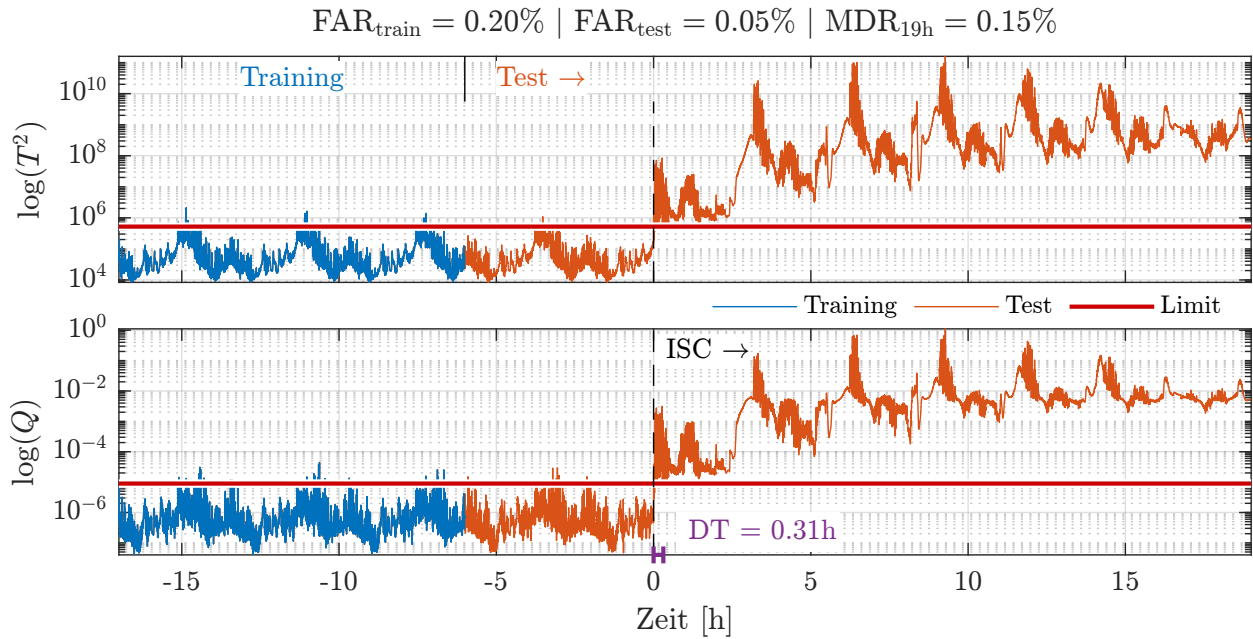
(a)  $T^2$ - und  $Q$ - Kontrollstatistiken.

(b) Von den Kontrollstatistiken abgeleitetes Detektionsmaß.


**Abbildung 4.32:** Ergebnisse des KPCA-basierten Monitorings für den Fall  $R_{\text{ISC}} = 10\Omega$  unter Verwendung der linearen Kernel-Funktion  $\kappa_{\text{lin}}$  (resultierende Anzahl an Hauptkomponenten:  $n_{\text{PC}} = 9$ ).

immer kleiner oder gleich 1 %, da, gemäß Gleichung (4.248), immer beide Kontrollstatistiken ihren Schwellenwert gleichzeitig überschreiten müssen. In allen Fällen liegt der  $\text{FAR}_{\text{test}}$  unter der  $\text{FAR}_{\text{train}}$ , was auf ein erfolgreiches Training ohne Überanpassung des Datenmodells hinweist und keinen Fehlalarm während der Validierungsphase verursacht. Für beide ISCs ist das nichtlineare Verfahren, basierend auf  $\kappa_{\text{mix}}$ , gegenüber  $\kappa_{\text{lin}}$  überlegen. Dies äußert sich






**Abbildung 4.33:** Ergebnisse des KPCA-basierten Monitorings für den Fall  $R_{\text{ISC}} = 10\Omega$  unter Verwendung der gemischten Kernel-Funktion  $\kappa_{\text{mix}}$  (resultierende Anzahl an Hauptkomponenten:  $n_{\text{PC}} = 20$ ).



**Abbildung 4.34:** Ergebnisse des KPCA-basierten Monitorings für den Fall  $R_{\text{ISC}} = 100\Omega$  unter Verwendung der linearen Kernel-Funktion  $\kappa_{\text{lin}}$  (resultierende Anzahl an Hauptkomponenten:  $n_{\text{PC}} = 8$ ).

in einer geringeren DT und MDR. Im Falle des weiter fortgeschrittenen  $10\Omega$ -ISCs ist der Vorteil der nichtlinearen Methode jedoch gering. Da der Betrag der Spannungsdifferenz der fehlerhaften Zelle schnell zunimmt, ist vor allem das Extrapolationsverhalten des gemischten Kerns entscheidend, das in beiden Fällen die lineare Kernel-Funktion dominiert. Zudem spielt bei niederohmigen ISCs die Wahl der Fenstergröße  $t_w$  des gleitenden Mittelwertfilters zunehmend eine Rolle, da sie zwar die Robustheit erhöht, gleichzeitig aber auch die DT



**Abbildung 4.35:** Ergebnisse des KPCA-basierten Monitorings für den Fall  $R_{\text{ISC}} = 100\Omega$  unter Verwendung der gemischten Kernel-Funktion  $\kappa_{\text{mix}}$  (resultierende Anzahl an Hauptkomponenten:  $n_{\text{PC}} = 30$ ).

verlängert. Der Vorteil der lokalen Kerne, in Form eines guten Interpolationsverhaltens und der daraus resultierenden höheren Empfindlichkeit gegenüber beginnenden Fehlern, zeigt sich für den größeren Widerstand  $R_{\text{ISC}} = 100\Omega$ . Aufgrund des im vorangegangenen Abschnitt gezeigten guten Interpolationsverhaltens halbiert sich die DT etwa von 5.63 h auf 2.51 h durch Einsatz des gemischten Kerns.

Zusammenfassend lässt sich schließen, dass bei weiter fortgeschrittenen Fehlern beide Kerne gleichermaßen geeignet sind. Der lineare Kern sollte jedoch aufgrund des geringeren Rechenaufwands bevorzugt werden. Wenn ein ISC in einer beginnenden Phase (höherer Widerstand) erkannt werden soll, zeigt der  $\kappa_{\text{mix}}$ -Kern eine höhere Empfindlichkeit, da er mehr Freiheitsgrade zur Anpassung an die Trainingsdaten hat (siehe auch Abbildung 4.39c).

#### 4.5.6 Vergleich und Diskussion

Um die Detektionsperformance der vorgestellten Ansätze einzuordnen, vergleicht Tabelle 4.5 die DTs mit anderen bereits existierenden Methoden. Bei den DTs handelt es sich um die ursprünglich von den Autoren ermittelten Werte [156, 211]. Neben der absoluten DT ist die relative Detektionszeit  $\text{DT}_0$  in Abhängigkeit von der Zellkapazität angegeben. Ähnlich wie bei der C-Rate erlaubt  $\text{DT}_0$  einen Vergleich für Zellen unterschiedlicher Kapazität. In ihrer Arbeit mit 50 Ah-Zellen vergleichen Lai, Yi u. a. bereits vier Methoden zur ISC-Erkennung, die in Tabelle 4.5 mit <sup>1</sup> gekennzeichnet sind [156]. Während die Spannungsdifferenz- und die SOC-Differenz-Methode in ihren Messdaten keinen 100  $\Omega$ -ISC erkennen, weist die SOC-Korrelationsmethode in beiden Fällen die kürzeste  $\text{DT}_0$  auf. Ouyang, Zhang u. a. wenden



**Tabelle 4.5:** Vergleich der Detektionszeiten des KPCA-basierten Monitorings mit bekannten Methoden aus der Literatur [156, 211].

Methode	$R_{\text{ISC}} = 10 \Omega$		$R_{\text{ISC}} = 100 \Omega$	
	DT	DT <sub>0</sub>	DT	DT <sub>0</sub>
	[h]	[min/Ah]	[h]	[min/Ah]
Statische Leckage <sup>1</sup>	20.30	24.4	202.70	243.2
Spannungsunterschied <sup>1</sup>	14.26	17.1	-	-
SOC-Unterschied <sup>1</sup>	9.32	11.2	-	-
SOC-Korrelation <sup>1</sup>	9.30	11.2	20.40	24.5
OCV-Unterschied <sup>2</sup>	1.30	3.9	11.32	34.0
Änderung des OCV-Unterschieds <sup>2</sup>	0.92	2.8	15.42	46.3
Innenwiderstand-Fluktuation <sup>2</sup>	1.28	3.8	4.72	14.2
PCA-basierte Überwachung <sup>3</sup>	0.37	0.9	5.63	13.5
KPCA-basierte Überwachung <sup>3</sup>	0.31	0.7	2.51	6.0

<sup>1</sup>SOC-Korrelationsmethode angewandt auf 50 Ah-Zellen [156]

<sup>2</sup>Äquivalenzparameter und Konsistenzmethode angewandt auf 20 Ah-Zellen [211]

<sup>3</sup>entwickelte Methode angewandt auf 25 Ah-Zellen

ihre Äquivalenzparameter- und Konsistenzmethode auf 20 Ah-Zellen an und schlagen drei verschiedene Fehlermerkmale für die ISC-Erkennung vor, die in Tabelle 4.5 mit <sup>2</sup> bezeichnet sind [211]. Während für fortgeschrittene ISCs die Änderung der OCV-Differenz die kürzeste DT hat, werden Soft-ISCs durch Schwankungen des Innenwiderstands früher erkannt. Für den 100  $\Omega$ -ISC liegen die normalisierten DTs der SOC-Korrelationsmethode und der Methoden von [211] in der gleichen Größenordnung. Im Fall des 10  $\Omega$ -Widerstands benötigt die Erkennung mit der SOC-Korrelationsmethode etwa dreimal so lange wie die Methoden von [211]. In allen Fällen beeinflussen die gewählten Detektionskriterien die DT. Wie Abschnitt 4.5.8 analysiert, sind diese Kriterien stets ein Kompromiss zwischen robustem Verhalten, das heißt einer niedrigen FAR, und einer kurzen DT (niedrige MDR). Die in dieser Arbeit vorgestellten Methoden, basierend auf der linearen PCA und der nichtlinearen KPCA, zeigen in allen Fällen kürzere DT<sub>0</sub>. Im 100  $\Omega$ -Fall liegt die DT der PCA-Überwachung in der Größenordnung der Innenwiderstand-Fluktuationmethode. Die KPCA-Methode erlaubt jedoch eine Halbierung der DT, was die hohe Empfindlichkeit gegenüber ISCs bestätigt. Im Falle des weiter fortgeschrittenen 10  $\Omega$ -ISCs verschwindet der Vorteil der KPCA-Überwachung in Bezug auf die DT. Aufgrund des höheren Kurzschlussstroms ist vor allem das Extrapolationsverhalten der Überwachungsmethode entscheidend, das bei beiden Methoden identisch ist. Der Vergleich mit den bestehenden Methoden zeigt jedoch eine deutliche Reduzierung der DT für die beiden Überwachungsmethoden mit der PCA und der KPCA.

### 4.5.7 Effiziente Wahl der Trainingsdaten

Vergleicht man die lineare PCA-basierte Überwachung aus Abschnitt 4.4 mit der nichtlinearen Überwachung mittels KPCA, so zeigt die nichtlineare Variante eine deutlich höhere Rechenkomplexität. Im linearen Fall besitzt die Kovarianzmatrix, die diagonalisiert werden muss, die Größe  $m \times m$ . Die Größe der Matrix hängt also nur von der Anzahl der gemessenen Spannungssignale ab, nicht aber von der Anzahl  $N$  der Trainingswerte. Für die Anwendung in Batteriesystemen steht die Anzahl  $m$  der Sensoren bereits bei der Auslegung fest und bewegt sich selbst für große Batteriesysteme mit Einzelzellspannungsmessung in der Größenordnung von wenigen Hundert (siehe Abschnitt 4.2.5). Die Lösung des Eigenwertproblems erfolgt offline. Das Online-Verfahren führt lediglich eine Basistransformation mittels der erhaltenen Offline-Lösung durch. Dies macht die lineare PCA-Überwachung zu einem leistungsfähigen und effizienten Werkzeug für die Online-Fehlerdiagnose. Obwohl die kernbasierte Methode unter Verwendung des Kernel-Tricks die abgebildeten Daten im Merkmalsraum nicht explizit berechnet, besitzt die zu diagonalisierende Gram-Matrix  $\mathbf{K}/(N-1)$  die Größe  $N \times N$ . Soll die Verteilung der Daten und ihre Kovarianzstruktur gut approximiert werden, benötigt das Training einen Datensatz mit Tausenden von Stichproben. Wählt man beispielsweise einen Trainingszeitraum von 16 h und Eingangsdaten mit einer Rate von 0.1 Hz, so resultieren  $N = 5760$  Trainingspunkte. Die zugehörige Gram-Matrix eines beispielhaften Batteriesystems mit 324 Zellen besitzt dann, verglichen mit der Kovarianzmatrix, die 316-fache Anzahl an Elementen. Selbst wenn die Gram-Matrix nur offline diagonalisiert werden muss, erfordert die Zentrierung der Testdaten im Merkmalsraum gemäß Gleichung (4.225) Rechenoperationen mit  $N$ -dimensionalen Vektoren zur Online-Überwachung. Aber auch die Offline-Diagonalisierung einer  $N \times N$ -Matrix stößt schnell an Speicher- und Rechengrenzen.

Betrachtet man den Raum, der von  $\{\Phi(\mathbf{z}_1), \dots, \Phi(\mathbf{z}_N)\}$  aufgespannt wird, stellt man in der Praxis fest, dass  $\text{span}\{\Phi(\mathbf{z}_1), \dots, \Phi(\mathbf{z}_N)\}$  ein Unterraum von  $\mathbb{F}$  mit einer deutlich kleineren Dimension als  $N$  ist [11]. Dies bedeutet, dass die Trainingsdaten in  $\mathbb{F}$  nicht linear unabhängig sind. Die Dimension des Unterraums  $\text{span}\{\Phi(\mathbf{z}_1), \dots, \Phi(\mathbf{z}_N)\}$  entspricht dem Rang der Kernel-Matrix  $n = \text{rank}(\mathbf{K}) \ll N$  [285]. Aufgrund der Äquivalenz der PCA und der KPCA mit linearer Kernel-Funktion  $\kappa_{\text{lin}} = \mathbf{z}_{\tau_1}^T \mathbf{z}_{\tau_2}$  (siehe Abschnitte 2.4.2 und 4.5.3) gilt für den linearen Kern  $n \leq m$ . Nach Bach und Jordan fällt auch der Rang von  $\mathbf{K}$  für Gauß-Kerne exponentiell ab, sodass sich eine Matrix-Approximation des Rangs  $n = \mathcal{O}(\log N)$  finden lässt [8]. Für polynomiell abfallende Eingangsverteilungen lässt sich eine Approximation  $n = \mathcal{O}(N^{1/d+\epsilon})$  mit einem beliebigen  $\epsilon > 0$  finden, wobei  $d$  der Polynomgrad ist [8].

Im Folgenden soll eine optimale Teilmenge an Trainingsdaten  $\tau \in [1, n]$  identifiziert werden, deren Abbildungen  $\{\Phi(\mathbf{z}_1), \dots, \Phi(\mathbf{z}_n)\}$  maximal linear unabhängig in  $\mathbb{F}$  sind. Das Verfahren, das auf einer unvollständigen Cholesky-Zerlegung basiert, orientiert sich am Algorithmus von Wang, Hu und Zhao und ähnelt der von Baudat und Anouar vorgeschlagenen Feature-Vektor-Methode [11, 285]. Alternative Ansätze wären die Sparse-Greedy-Approximation von Smola

und Schölkopf oder die Nyström-Approximation nach Williams und Seeger [268, 293]. Sei  $n = \text{rank}(\mathbf{K}) \ll N$  die Anzahl der linear unabhängigen Feature-Vektoren in  $\mathbb{F}$ , dann genügen  $n$  Eigenvektoren  $\mathbf{p}_s \in \mathbb{R}^n$ ,  $s \in [1, n]$ , um  $\mathbb{F}$  aufzuspinnen. Ohne Verlust der Allgemeingültigkeit werden  $s$  Abbildungen  $\Phi(\mathbf{z}_s)$  gewählt, die eine Basis für den  $n$ -dimensionalen Unterraum bilden, sodass

$$\text{span}\{\Phi(\mathbf{z}_1), \dots, \Phi(\mathbf{z}_N)\} \equiv \text{span}\{\Phi(\mathbf{z}_1), \dots, \Phi(\mathbf{z}_n)\}. \quad (4.251)$$

Führt man die Vektoren  $\varphi_s = [\varphi_{s1} \dots \varphi_{sn}]^T \in \mathbb{R}^n$  ein, so lassen sich die Eigenvektoren als

$$\mathbf{p}_s = \sum_{\tau=1}^n \varphi_{s\tau} \Phi(\mathbf{z}_\tau) \quad (4.252)$$

schreiben. Für die restlichen  $\tau \in [n+1, N]$  Abbildungen  $\Phi(\mathbf{z}_\tau)$  existieren Koeffizienten  $p_{\tau j}$ , sodass sich  $\Phi(\mathbf{z}_\tau)$  durch

$$\Phi(\mathbf{z}_\tau) = \sum_{j=1}^n p_{\tau j} \Phi(\mathbf{z}_j) \quad (4.253)$$

ausdrücken lässt. Für die Gram-Matrix folgt

$$\begin{aligned} \mathfrak{G} &= \frac{1}{N-1} \sum_{\tau=1}^N \Phi(\mathbf{z}_\tau) \Phi(\mathbf{z}_\tau)^T \\ &= \frac{1}{N-1} \left( \sum_{\tau=1}^n \Phi(\mathbf{z}_\tau) \Phi(\mathbf{z}_\tau)^T + \sum_{\tau=n+1}^N \sum_{j=1}^n p_{\tau j} \Phi(\mathbf{z}_j) \sum_{k=1}^n p_{\tau k} \Phi(\mathbf{z}_k)^T \right) \\ &= \frac{1}{N-1} \left( \sum_{\tau=1}^n \Phi(\mathbf{z}_\tau) \Phi(\mathbf{z}_\tau)^T + \sum_{j=1}^n \sum_{k=1}^n \left( \sum_{\tau=n+1}^N p_{\tau j} p_{\tau k} \right) \Phi(\mathbf{z}_j) \Phi(\mathbf{z}_k)^T \right) \\ &= \frac{1}{N-1} \sum_{j=1}^n \sum_{k=1}^n q_{jk} \Phi(\mathbf{z}_j) \Phi(\mathbf{z}_k)^T, \end{aligned} \quad (4.254)$$

wobei

$$q_{jk} = \begin{cases} \sum_{\tau=n+1}^N p_{\tau j} p_{\tau k} + 1, & j = k \\ \sum_{\tau=n+1}^N p_{\tau j} p_{\tau k}, & j \neq k \end{cases}. \quad (4.255)$$

Setzt man die Gram-Matrix und die Eigenvektoren in (4.207) ein, erhält man

$$\frac{1}{N-1} \sum_{j=1}^n \sum_{k=1}^n q_{jk} \Phi(\mathbf{z}_j) \Phi(\mathbf{z}_k)^T \left( \sum_{\tau=1}^n \varphi_{s\tau} \Phi(\mathbf{z}_\tau) \right) = \lambda_s \sum_{\tau=1}^n \varphi_{s\tau} \Phi(\mathbf{z}_\tau). \quad (4.256)$$

Die Multiplikation beider Seiten von (4.256) mit  $\Phi(\mathbf{z}_l)^T$ ,  $l \in [1, n]$  ergibt  $n$  Gleichungen, die eine Darstellung in Skalarprodukt-Notation ermöglichen:

$$\frac{1}{N-1} \sum_{j=1}^n \sum_{k=1}^n q_{jk} \Phi(\mathbf{z}_l)^T \Phi(\mathbf{z}_j) \sum_{\tau=1}^n \varphi_{s\tau} \Phi(\mathbf{z}_k)^T \Phi(\mathbf{z}_\tau) = \lambda_s \sum_{\tau=1}^n \varphi_{s\tau} \Phi(\mathbf{z}_l)^T \Phi(\mathbf{z}_\tau). \quad (4.257)$$

Die in (4.213) eingeführte Kernel-Funktion  $\kappa(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2})$  erlaubt die Notation

$$\frac{1}{N-1} \sum_{j=1}^n \sum_{k=1}^n q_{jk} \kappa(\mathbf{z}_l, \mathbf{z}_j) \left( \sum_{\tau=1}^n \varphi_{s\tau} \kappa(\mathbf{z}_k, \mathbf{z}_{\tau}) \right) = \lambda_s \sum_{\tau=1}^n \varphi_{s\tau} \kappa(\mathbf{z}_l, \mathbf{z}_{\tau}). \quad (4.258)$$

Mit der reduzierten Kernel-Matrix

$$\mathbf{K}_0 = (\widehat{\mathbf{K}}_{\tau j})_{\tau=1, \dots, n; j=1, \dots, n} \quad (4.259)$$

und

$$\mathbf{Q} = (q_{jk})_{j=1, \dots, n; k=1, \dots, n} \in \mathbb{R}^{n \times n} \quad (4.260)$$

$$\boldsymbol{\varphi}_s = (\varphi_{s\tau})_{\tau=1, \dots, n} \in \mathbb{R}^n \quad (4.261)$$

folgt für (4.258)

$$\frac{1}{N-1} \mathbf{K}_0 \mathbf{Q} \mathbf{K}_0 \boldsymbol{\varphi}_s = \lambda_s \mathbf{K}_0 \boldsymbol{\varphi}_s. \quad (4.262)$$

Die Lösung von (4.262) führt zu dem Eigenwertproblem

$$\frac{1}{N-1} \mathbf{Q} \widehat{\mathbf{K}} \boldsymbol{\varphi}_s = \lambda_s \boldsymbol{\varphi}_s \quad (4.263)$$

mit der reduzierten Matrix  $\widehat{\mathbf{K}} = \mathbf{Q} \mathbf{K}_0 \in \mathbb{R}^{n \times n}$ . Für die Anwendung der KPCA zur Fehlerdiagnose stellt sich die Frage, wie sich die Approximation  $\widehat{\mathbf{K}} \approx \mathbf{K}$  finden und die optimale Wahl der  $n$  Samples treffen lässt. Da  $\mathbf{K}$  eine positiv semidefinite Matrix ist, ist mithilfe der Cholesky-Zerlegung stets eine Faktorisierung  $\mathbf{K} = \mathbf{G} \mathbf{G}^T$  mit der Dreiecksmatrix  $\mathbf{G} \in \mathbb{R}^{N \times N}$  möglich [8]. Ziel ist es, eine Approximation  $\widehat{\mathbf{G}} \in \mathbb{R}^{N \times n}$  für  $\mathbf{G}$  zu finden, die nur  $n$  Spalten und die zugehörige optimale Permutationsmatrix  $\mathbf{P}$  hat. Die unvollständige Cholesky-Zerlegung gemäß Algorithmus 4.1 ermöglicht solche Matrizen  $\mathbf{P}$  und  $\widehat{\mathbf{G}}$  zu finden. Im Unterschied zur gewöhnlichen Cholesky-Zerlegung überspringt dieser Ansatz alle Pivots (Diagonalelemente von  $\mathbf{G}$ ), die kleiner als ein Schwellwert sind. Gegeben die positiv semidefinite Gram-Matrix  $\mathbf{K} \in \mathbb{R}^{N \times N}$  und die Toleranz  $\eta$ , findet Algorithmus 4.1 eine untere Dreiecksmatrix  $\widehat{\mathbf{G}}$  und eine Permutationsmatrix  $\mathbf{P}$ , sodass  $\|\mathbf{P} \mathbf{K} \mathbf{P}^T - \widehat{\mathbf{G}} \widehat{\mathbf{G}}^T\| \leq \eta$  gilt. Die Schreibweise  $\mathbf{G}_{a,b,c,d}$  bezeichnet eine Untermatrix von  $\mathbf{G}$ , bestehend aus den Zeilen von Index  $a$  bis  $b$  und den Spalten von Index  $c$  bis  $d$ . Im Algorithmus wird die Permutationsmatrix  $\mathbf{P}$  mit der Einheitsmatrix und die Diagonale von  $\mathbf{G}$  mit der Diagonale von  $\mathbf{K}$  initialisiert. Solange die Summe aller  $N - \tau$  Pivots größer als der Schwellwert  $\eta$  ist, berechnet der Algorithmus sukzessive die  $\tau \in [1, n]$  ersten Spalten von  $\mathbf{G}$ . Dafür wird der Index  $j^*$  des größten Diagonalelements ermittelt (Zeile 6). Die Permutationsmatrix  $\mathbf{P}$  aktualisiert das Verfahren entsprechend einem Tausch der  $\tau$ -ten und  $j^*$ -ten Spalte (Zeile 7). In der modifizierten Gram-matrix  $\mathbf{K}'$  werden die  $\tau$ -te und die  $j^*$ -te Spalte (Code Zeile 8) und Zeile (Code Zeile 9) getauscht. Aufgrund

**Algorithmus 4.1** Unvollständige Cholesky-Zerlegung [8]**Input:**  $\mathbf{K} \in \mathbb{R}^{N \times N}$ ,  $\eta$ 


---

```

1:  $\tau \leftarrow 1$ ,  $\mathbf{K}' \leftarrow \mathbf{K}$ ,  $\mathbf{P} \leftarrow \mathbf{I}$ ,  $(\mathbf{G}_{jj})_{j \in [1, N]} \leftarrow (\mathbf{K}_{jj})_{j \in [1, N]}$  ▷ Initialisierung
2: while  $\sum_{j=\tau}^N \mathbf{G}_{jj} > \eta$  do
3:    $j^* \leftarrow \arg \max_{j \in [\tau, N]} \mathbf{G}_{jj}$  ▷ Finde ein neues, bestes Element  $j^*$ 
4:    $\mathbf{P}_{\tau\tau} \leftarrow 0$ ,  $\mathbf{P}_{j^*j^*} \leftarrow 0$ ,  $\mathbf{P}_{\tau j^*} \leftarrow 1$ ,  $\mathbf{P}_{j^* \tau} \leftarrow 1$  ▷ Aktualisiere Permutationsmatrix
5:    $\mathbf{K}'_{1:N, \tau} \leftrightarrow \mathbf{K}'_{1:N, j^*}$  ▷ Permutiere  $\tau$  und  $j^*$  in  $\mathbf{K}'$  (Spalte)
6:    $\mathbf{K}'_{\tau, 1:N} \leftrightarrow \mathbf{K}'_{j^*, 1:N}$  ▷ Permutiere  $\tau$  und  $j^*$  in  $\mathbf{K}'$  (Zeile)
7:    $\mathbf{G}_{\tau, 1:\tau} \leftrightarrow \mathbf{G}_{j^*, 1:\tau}$  ▷ Aktualisiere  $\mathbf{G}$  (aufgrund der Permutation)
8:    $\mathbf{G}_{\tau\tau} \leftarrow \sqrt{\mathbf{K}'_{\tau\tau}}$ 
9:    $\mathbf{G}_{\tau+1:N, \tau} \leftarrow \frac{1}{\mathbf{G}_{\tau\tau}} \left( \mathbf{K}'_{\tau+1:N, \tau} - \sum_{j=1}^{\tau-1} \mathbf{G}_{\tau+1:N, j} \mathbf{G}_{\tau j} \right)$  ▷ Berechne  $\tau$ -te Spalte von  $\mathbf{G}$ 
10:  for  $j = \tau + 1$  to  $N$  do
11:     $\mathbf{G}_{jj} \leftarrow \mathbf{K}_{jj} - \sum_{k=1}^{\tau} \mathbf{G}_{jk}^2$  ▷ Aktualisiere Diagonalelemente
12:  end for
13:   $\tau \leftarrow \tau + 1$ 
14: end while
15:  $n \leftarrow \tau - 1$ 
16:  $\widehat{\mathbf{G}} \leftarrow \mathbf{G}_{1:N, n}$ 
Output:  $\widehat{\mathbf{G}} \in \mathbb{R}^{N \times n}$ ,  $\mathbf{P} \in \mathbb{R}^{N \times N}$ 


```

---

der Permutationen tauscht der Algorithmus die  $\tau$ -te Zeile und die  $j^*$ -te Zeile von  $\mathbf{G}$  mit bereits berechneten Elementen ebenfalls. Die verbleibenden Elemente der  $\tau$ -ten Spalte in  $\mathbf{G}$  berechnet Zeile 12. Die verbleibenden  $j \in [\tau + 1, N]$  Diagonalelemente ergänzt Zeile 14. Anstelle der Toleranz  $\eta$  könnte auch eine Bedingung an die maximale Anzahl an Spalten  $n_{\max}$  von  $\widehat{\mathbf{G}}$  gesetzt werden.

Obwohl das in Algorithmus 4.1 gezeigte Verfahren aussieht, als müsste die vollständige  $N \times N$  große Gram-Matrix  $\mathbf{K}$  berechnet werden, benötigt eine effiziente Implementierung die Gram-Matrix nur spaltenweise (Zeile 12) oder die Diagonale (zum Beispiel in Zeile 4) der Gram-Matrix. Dadurch ist die Gesamt-Komplexität der unvollständigen Cholesky-Zerlegung  $\mathcal{O}(n^2 N)$  und damit linear in  $N$ . Anstelle der  $N \times N$  Gram-Matrix muss auch nur die Diagonale von  $\mathbf{K}$  gespeichert werden, weshalb der Speicherplatzbedarf ebenfalls linear in  $N$  ist. Er beträgt  $\mathcal{O}(nN)$  [8].


Basierend auf der unvollständigen Cholesky-Zerlegung lässt sich eine optimale Teilmenge von Trainings-Samples finden. Die Gram-Matrix  $\mathbf{K}$  wird durch  $\widehat{\mathbf{K}} = \widehat{\mathbf{G}}\widehat{\mathbf{G}}^T$  approximiert und mit (4.219) zentriert.



**Abbildung 4.36:** Projektion der ersten sechs Kernel-Hauptkomponenten mit den zugehörigen Eigenwerten  $\lambda_s$  (oben, links) für die Spalten  $\zeta_4$  und  $\zeta_{10}$  der Trainingsdatenmatrix  $\mathbf{Z}$  für den Fall  $R_{\text{ISC}} = 10 \text{ k}\Omega$  unter Verwendung eines gemischten Kerns mit den Parametern  $\omega_{\text{lin}} = 0.05$  und  $\sigma = 1.8$ .

### Exemplarische Anwendung der unvollständigen Cholesky-Zerlegung

Die theoretische Herleitung zur effizienten Auswahl der Trainingsdaten wird im Folgenden anhand der Messdaten analysiert und diskutiert. Um eine zweidimensionale Darstellung zu ermöglichen erfolgt die Analyse anhand der zwei exemplarischen SMG-Zellen 4 und 10 (siehe Abbildung 4.18). Bei der Zelle 10 handelt es sich um die Zelle, an der der ISC emuliert wird. Die Datenvorverarbeitung der Spannungsmessungen für den Fall  $R_{\text{ISC}} = 10 \text{ k}\Omega$  erfolgt über die in Abschnitt 4.3 vorgestellten Methoden, sodass sich die Skalarprodukte im Merkmalsraum  $\mathbb{F}$  berechnen lassen. Eine Trainingsdauer von 16 h Training mit einer Rate von 0.1 Hz resultiert in  $N = 5760$  Trainings-Samples. Die Spalten  $\zeta_4$  und  $\zeta_{10}$  der Trainingsdatenmatrix  $\mathbf{Z}$  sind in Abbildung 4.36 dargestellt. Zusätzlich sind die ersten  $s \in [1, 6]$  Eigenwerte  $\lambda_s$ , basierend auf allen  $N$ -Trainingspunkten, in den Diagrammen oben links angegeben. In Farbe sind die Projektionen der entsprechenden Kernel-Hauptkomponenten  $\mathbf{p}_s$  in den Eingangsraum dargestellt. Da die Projektionen in absteigender Reihenfolge nach der Größe der zugehörigen Eigenwerte sortiert sind, sind sie bis auf das Vorzeichen eindeutig. Wie in Abschnitt 4.5.3 diskutiert, wird eine Kombination aus einem globalen und einem lokalen Kern verwendet, um eine hohe Empfindlichkeit für Soft-ISCs und gleichzeitig ein robustes Verhalten für weiter fortgeschrittene ISCs zu gewährleisten. Für das in Abbildung 4.36 gezeigte Beispiel kommt dafür eine Kombination aus dem linearen und dem Gaußschen Kern zum Einsatz. Der globale, lineare Kern ist für Konturlinien in Form von Geraden zuständig. Dies hat den Vorteil, dass für Punkte mit großem Abstand zum Trainingsdatenzentrum noch ein Gradient in den Eigenvektoren vorhanden ist. Aufgrund des Einflusses des lokalen Gauß-Kerns sind die


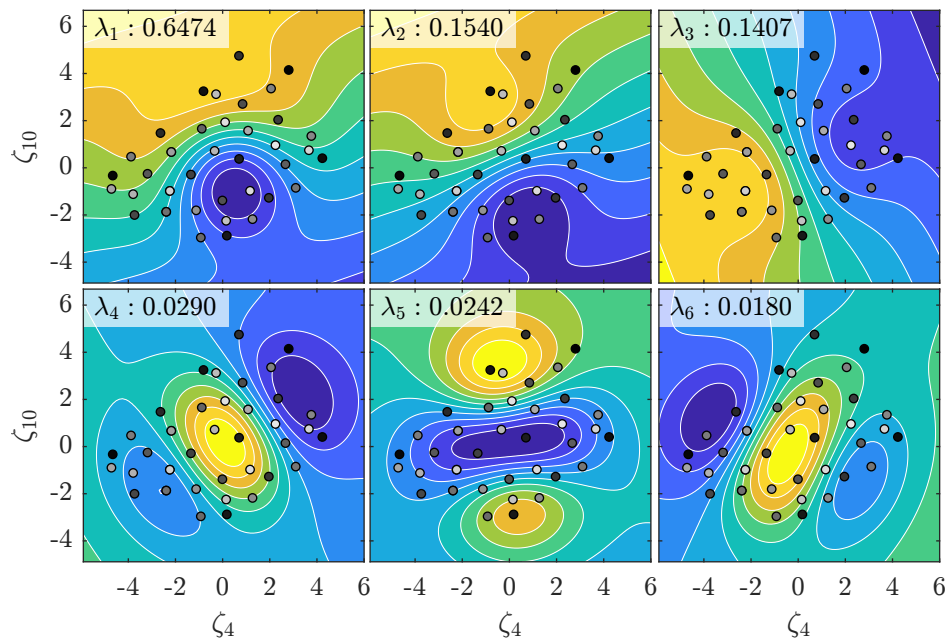


**Abbildung 4.37:** Vom Algorithmus 4.1 ausgewählte Spalten der Kernel-Matrix, die zu den Punkten mit der geringsten linearen Abhängigkeit im Merkmalsraum  $\mathbb{F}$  korrespondieren.

Konturlinien basierend auf der Verteilung der Trainingsdaten *gebogen*. Allerdings hat die in Gleichung (4.217) zu diagonalisierende Kernel-Matrix  $\mathbf{K}$  die Größe  $5760 \times 5760$  und die Online-Überwachung erfordert alle 10 s die Zentrierung eines 5760-dimensionalen Vektors, siehe Gleichung (4.225). Daher ist das Ziel, eine Approximation des Merkmalsraums durch eine geringere Anzahl  $n$  von Trainingsdaten aufzuspannen. In Abbildung 4.37 sind die ersten  $j^* \in [1, 6]$  Punkte der von Algorithmus 4.1 gewählten Teilmenge hervorgehoben. Zusätzlich sind die Projektionen der nicht-zentrierten Kernel-Vektoren

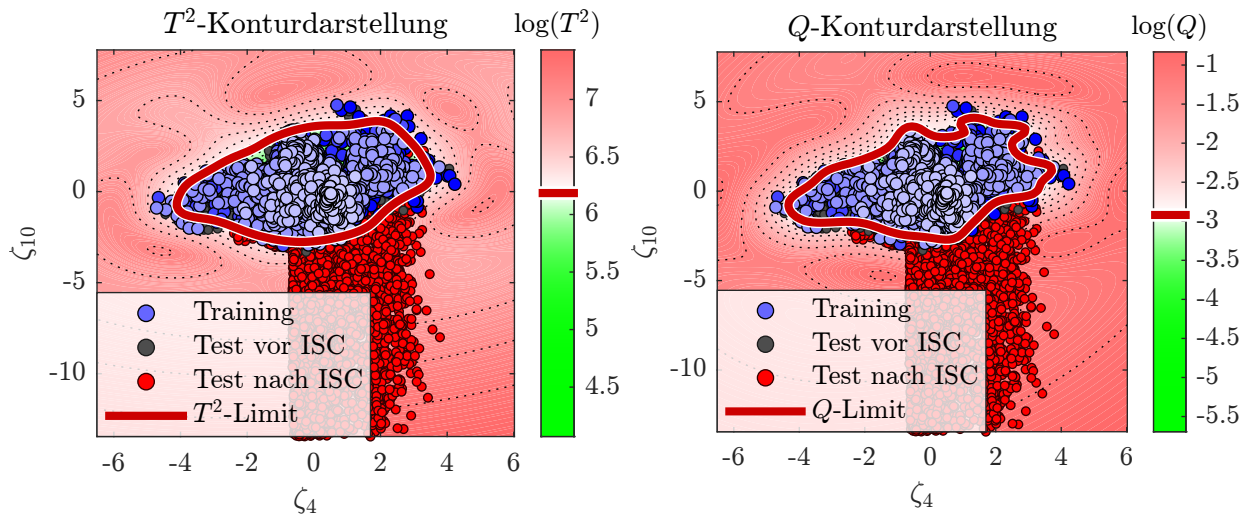
$$\tilde{\mathbf{k}}_t = \left[ \kappa(\mathbf{z}_1, \mathbf{z}_{j^*}) \dots \kappa(\mathbf{z}_t, \mathbf{z}_{j^*}) \dots \kappa(\mathbf{z}_{N_{\text{grid}}}, \mathbf{z}_{j^*}) \right]^T \in \mathbb{R}^{N_{\text{grid}}} \quad (4.264)$$

auf den Eingangsraum mit Gitterpunkten  $\mathbf{z}_t \in \mathbb{R}^2$  farbig dargestellt. Die Konturlinien entsprechen konstanten Skalarprodukt-Werten. Die gezeigte Teilmenge besteht aus den Punkten mit der geringsten linearen Abhängigkeit und umfasst daher die am besten geeigneten Punkte zur Approximation des Merkmalsraums. Wählt man nur die in Abbildung 4.37 gezeigten  $n = 6$  Punkte repräsentativ für die Menge aller  $N$  Punkte, so erhält man die in Abbildung 4.38a gezeigten Kernel-Hauptkomponenten und Eigenwerte. Die Farbe der Punkte von schwarz bis hellgrau entspricht ihrer Sortierung nach Algorithmus 4.1. Der erste Punkt ist schwarz. Selbst bei der gewählten, sehr kleinen Teilmenge von  $n = 6$  Punkten liegen die Eigenwerte bereits in der richtigen Größenordnung. Der Verlauf der ersten drei Kernel-Hauptkomponenten ähnelt den Konturlinien aus Abbildung 4.36. Das nicht eindeutige Vorzeichen bewirkt teilweise eine Invertierung der Konturfärbungen. Zusätzlich ist eine positive Rotation der Kernel-Hauptkomponenten zu beobachten. Abbildung 4.38b zeigt beispielhaft

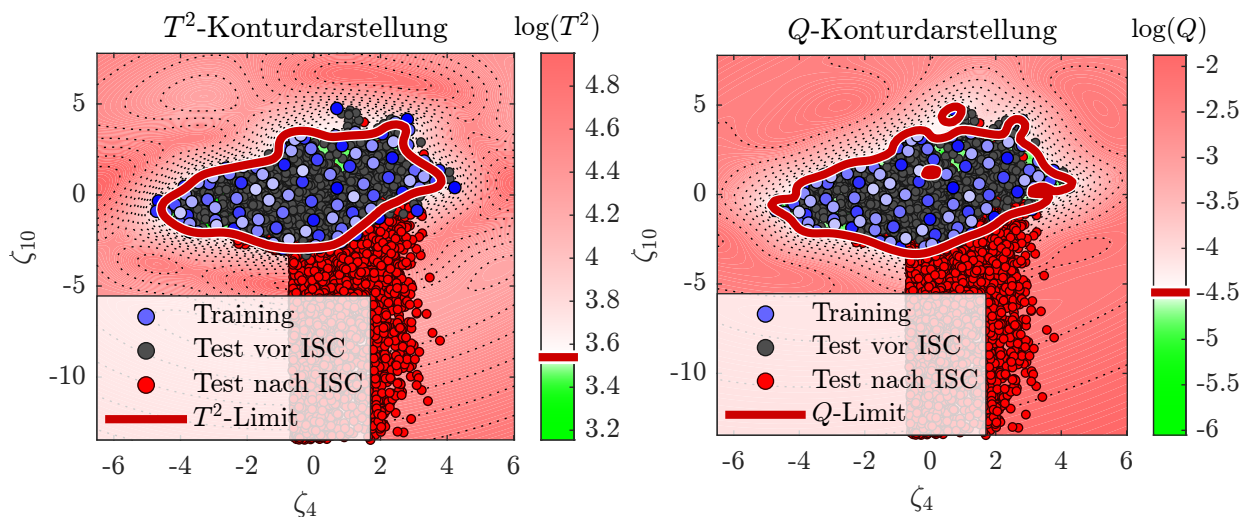
(a) Approximation von  $\mathbb{F}$  mit  $n = 6$  Trainings-Samples.(b) Approximation von  $\mathbb{F}$  mit  $n = 40$  Trainings-Samples.**Abbildung 4.38:** Approximation des Merkmalraums  $\mathbb{F}$  basierend auf der unvollständigen Cholesky-Zerlegung.

eine Approximation mit einer Teilmenge von  $n = 40$  Punkten. Alle sechs größten Eigenwerte stimmen in den ersten vier Nachkommastellen vollständig mit den Eigenwerten aus Abbildung 4.36 überein. Auch der Verlauf der Kernel-Hauptkomponenten entspricht bis auf das Vorzeichen weitgehend dem Verlauf der Kernel-Hauptkomponenten auf Basis der vollständigen Trainingsdaten. Allerdings wurde die Größe der zu speichernden und zu diagonalisierenden





(a) Konturdarstellung der  $T^2$ -Statistik ( $n_{PC} = 21$ ). (b) Konturdarstellung der  $Q$ -Statistik ( $n_{PC} = 21$ ).




(c) Konturdarstellung der  $T^2$ -Statistik nach optimaler Trainingsdatenwahl ( $n_{PC} = 25$ ). (d) Konturdarstellung der  $Q$ -Statistik nach optimaler Trainingsdatenwahl ( $n_{PC} = 25$ ).

**Abbildung 4.39:** Konturdarstellung der  $T^2$ - und  $Q$ -Kontrollstatistik in der  $\zeta_4\zeta_{10}$ -Ebene basierend auf der vollständigen Datenmatrix (a, b) mit  $N = 5760$  und der Approximation durch die unvollständige Cholesky-Zerlegung (c, d). Für  $\eta = 10^{-6}$  resultiert  $n = 116$ .

Kernel-Matrix von  $5760 \times 5760$  auf die Größe  $40 \times 40$  reduziert, was einer Reduzierung um den Faktor  $144^2 = 20\,736$  entspricht.

Zur Online-Überwachung werden die  $T^2$ - und  $Q$ -Statistiken nach (4.228) und (4.229) berechnet. Abbildung 4.39 zeigt die resultierenden Konturdarstellungen der Teststatistiken für den Eingangsraum. Während die Berechnung der Teststatistiken in den Abbildungen 4.39a und 4.39b auf der vollen Kernel-Matrix  $\mathbf{K} \in \mathbb{R}^{5760 \times 5760}$  basiert, verwenden die Abbildungen 4.39c und 4.39d die Approximation nach Algorithmus 4.1. Bei einer gewählten Toleranz  $\eta = 10^{-6}$  resultieren  $n = 116$  Punkte. Die Trainingsdaten sind in verschiedenen Blautönen dargestellt. In den Abbildungen 4.39a und 4.39b sind die Trainingspunkte zeitlich sortiert, in den Abbil-



**Abbildung 4.40:** Abnahme der Summe der Diagonalelemente von  $\mathbf{G}$  (Toleranz  $\eta$ ), abhängig von der Trainingsuntermenge  $n$  und der Anzahl der Dimensionen  $m$ .

dungen 4.39c und 4.39d entspricht die Sortierung der Reihenfolge, in der der Algorithmus 4.1, Zeile 6, die Punkte wählt. Dunkelblau entspricht dem ersten Punkt beziehungsweise dem größten Diagonalelement. Die Testpunkte vor dem Auftreten des ISCs sind in grau dargestellt. Nach dem Auftreten des ISCs von  $R_{\text{ISC}} = 10 \text{ k}\Omega$  sind die Testpunkte in rot markiert. Für den grün dargestellten Bereich liegt die jeweilige Statistik unter ihrem Grenzwert. Das mittels einer Kerndichteschätzung ermittelte obere Limit basiert für beide Kontrollstatistiken auf einer 99%-Konfidenz und wird als rote durchgezogene Linie dargestellt. Bereiche oberhalb des UCLs sind in Rot dargestellt. Gemäß (4.248)-(4.250) wird die Vereinigung der grünen Bereiche der  $T^2$ - und  $Q$ -Statistiken als fehlerfrei angesehen. Wie in Abschnitt 4.5.4 beschrieben, ist der lineare Kern für das globale Verhalten in Form von Ellipsen verantwortlich, da sich für linear zusammenhängende Variablen eine multivariate Normalverteilung ergibt [284]. Das lokale Verhalten dominiert der Gauß-Kern. Wie in Abbildung 4.39d zu erkennen ist, ergibt sich deshalb nicht unbedingt ein zusammenhängender Unterraum, in dem die Daten als fehlerfrei bewertet werden. Im gezeigten Beispiel ist der Unterraum auch nach Vereinigung des  $T^2$ - und  $Q$ -Unterraumes nicht zusammenhängend. Im Fall der vollen Datenmatrix liegen 99.32% der Testdaten innerhalb der Vereinigungsmenge beider Statistiken, bevor der ISC auftritt (grau). Dies entspricht einer Falschalarmrate von  $\text{FAR} = 0.68\%$ . Die MDR innerhalb von 48 h nach Auftreten des ISCs beträgt  $\text{MDR}_{48\text{h}} = 26.24\%$ . Im Falle der Approximation ergeben sich  $\text{FAR} = 0.16\%$  und  $\text{MDR}_{48\text{h}} = 28.45\%$ . Die Methode mit dem vollständigen Trainingssatz besitzt also eine niedrigere MDR, die Methode mit der Teilmenge an Trainingsdaten hingegen eine niedrigere FAR. Da die Fehlerdetektion immer ein Kompromiss zwischen niedriger FAR und niedriger MDR beziehungsweise DT ist, kann die Detektionsperformance


beider Ansätze als gleichwertig angesehen werden. Somit geht mit der Komplexitätsreduktion keine Verschlechterung der Fehlerdiagnose einher.

Abbildung 4.40 zeigt die Abnahme der Summe der Diagonalelemente  $\sum_{j=i}^N \mathbf{G}_{jj}$  während der Ausführung von Algorithmus 4.1, abhängig von der Größe der Trainingsuntermenge  $n$  und der Anzahl der Dimensionen  $m$ . Bei einer konstanten Anzahl von Trainingspunkten ist zu beobachten, dass die Verteilung der Daten mit zunehmender Anzahl von Dimensionen schlechter approximiert werden kann. Dieser Effekt wird auch als *Fluch der Dimensionalität* bezeichnet [14, 192]. Für die ersten Punkte  $n$  ist jedoch eine schnelle Abnahme von  $\sum_{j=i}^N \mathbf{G}_{jj}$  zu beobachten. Dies ist auf den linearen Kern zurückzuführen. Aufgrund der Äquivalenz der PCA und der KPCA mit linearem Kern, beschreiben im Falle einer linearen Kernel-Funktion bereits maximal  $n = m$  Punkte den Merkmalsraum  $\mathbb{F}$  vollständig. Somit lässt sich für eine Wahl von  $n = m$  mindestens die Detektionsleistung des linearen Verfahrens garantieren. Dies macht die Methode robust gegenüber einer hohen Anzahl von Spannungssignalen, wie sie in großen Batteriepacks vorkommen. Die Hinzunahme weiterer Punkte ( $n > m$ ) verbessert die Detektionsleistung durch den Einfluss des Gauß-Kerns.


#### 4.5.8 Einfluss der Parameter der gemischten Kernel-Funktion

Ausgehend von den  $m = 12$  Spannungsmessungen untersucht dieser Abschnitt den Einfluss der Gewichtung  $\omega_{\text{gauss}} = 1 - \omega_{\text{lin}}$  des linearen und des Gauß-Kerns sowie den Einfluss des Kernel-Parameters  $\sigma$ . Dazu werden die Methoden aus Abschnitt 4.5 auf den SMG-Datensatz  $R_{\text{ISC}} = 10 \text{ k}\Omega$  mit verschiedenen Wahlen von  $\omega_{\text{gauss}}$  und  $\sigma$  angewandt. Abbildungen 4.41 und 4.42 zeigen die resultierenden FARs im Training und im Test. Die resultierenden MDRs innerhalb der ersten 48 h nach Auftreten des  $R_{\text{ISC}} = 10 \text{ k}\Omega$ -Fehlers zeigt Abbildung 4.43. Für  $\omega_{\text{gauss}} = 0$  resultiert mit  $\omega_{\text{lin}} = 1$  das lineare Monitoring basierend auf der PCA. Der lineare Kern zeigt eine niedrige FAR im Training und im Test, weist aber auch eine hohe MDR und DT auf. Umgekehrt resultiert für  $\omega_{\text{gauss}} = 1$  die KPCA mit einem reinen Gauß-Kern. Für  $\omega_{\text{gauss}} = 1$  ergibt sich eine niedrige MDR, jedoch ist auch ein signifikanter Anstieg der FAR im Training und im Test zu beobachten. Die  $\text{FAR}_{\text{train}}$  ist aufgrund ihrer Definition immer kleiner als 1 %, die  $\text{FAR}_{\text{test}}$  kann 1 % überschreiten, weist dann jedoch auf eine Überanpassung an die Trainingsdaten hin. Dies ist besonders bei kleinem  $\sigma$  und hohem  $\omega_{\text{gauss}}$  zu beobachten. In diesem Fall erreicht der Algorithmus die niedrige MDR und kurze DT auf Kosten einer hohen FAR. Durch das schlechte Extrapolationsverhalten des reinen Gauß-Kerns ist zu erwarten, dass mit fortschreitendem Fehler das in Abschnitt 4.5.3 diskutierte Verhalten eintritt. Dabei detektiert das Verfahren im Falle einer größeren Spannungsdifferenz keine Anomalie mehr, wodurch auch die MDR deutlich ansteigt. Ein kleines  $\sigma$  begünstigt dieses unerwünschte Verhalten zusätzlich. Für den Bereich außerhalb von  $0.8 < \omega_{\text{gauss}} < 1$  und  $3 < \sigma < 10$  gilt das Verhältnis

$$\frac{\text{FAR}_{\text{test}}}{\text{FAR}_{\text{train}}} \approx 1. \quad (4.265)$$




**Abbildung 4.41:** Resultierende FAR im Training bei einer Variation der Gewichtung  $\omega_{\text{gauss}}$  und dem Kernel-Parameter  $\sigma$ .




**Abbildung 4.42:** Resultierende FAR im Test bei einer Variation der Gewichtung  $\omega_{\text{gauss}}$  und dem Kernel-Parameter  $\sigma$ .

Eine kleine Wahl von  $\sigma < 3$  führt unabhängig von der Gewichtung  $\omega_{\text{gauss}}$  zu einer großen MDR und kleinen FAR, vergleichbar mit dem rein linearen Verhalten für  $\omega_{\text{gauss}} = 0$ . Dies lässt sich durch einen stark unzusammenhängenden Raum erklären (siehe Abbildung 4.39d), in dem das globale Verhalten des linearen Kerns dominiert. Mit Ausnahme der Extremwerte  $\omega_{\text{gauss}} \rightarrow 1$ ,  $\omega_{\text{gauss}} \rightarrow 0$ ,  $\sigma \rightarrow 0$  zeigen die FAR und MDR ein Plateau mit einer geringen Empfindlichkeit gegenüber Parameteränderungen in  $\omega_{\text{gauss}}$  und  $\sigma$ . Dies deutet auf eine hohe



**Abbildung 4.43:** Resultierende MDR innerhalb der ersten 48 h nach Auftreten des ISCs bei einer Variation der Gewichtung  $\omega_{\text{gauss}}$  und dem Kernel-Parameter  $\sigma$ .



**Abbildung 4.44:** MDR innerhalb der ersten 48 h nach Emulation des ISCs und FAR im Test bei einer Variation der Gewichtung  $\omega_{\text{gauss}}$  und dem Kernel-Parameter  $\sigma$ .

Robustheit in Bezug auf die Parameterwahl hin.

Um eine Pareto-effiziente Wahl von  $\omega_{\text{gauss}}$  und  $\sigma$  zu finden, die eine geringe  $\text{FAR}_{\text{test}}$  bei gleichzeitig geringer  $\text{MDR}_{48\text{h}}$  besitzt, werden die Ergebnisse aus den Abbildungen 4.42 und 4.43 in Abbildung 4.44 mit  $\text{MDR}_{48\text{h}}$  auf der Abszisse und  $\text{FAR}_{\text{test}}$  auf der Ordinate aufgetragen. Die Größe der Punkte entspricht den Werten von  $\sigma$  und die Farbe entspricht der Gewichtung  $\omega_{\text{gauss}}$ . Die grau dargestellten Konturlinien entsprechen konstanten Produkten von  $\text{MDR}_{48\text{h}}$

und  $\text{FAR}_{\text{test}}$ . In Abbildung 4.44 ist zu erkennen, dass eine höhere Gewichtung des Gauß-Kerns tendenziell zu einer höheren  $\text{FAR}_{\text{test}}$  und einer niedrigeren  $\text{MDR}_{48\text{h}}$  führt. Eine stärkere Gewichtung des linearen Kerns hat den gegenteiligen Effekt. Die gelben Punkte mit  $\omega_{\text{gauss}} = 1$  werden von Punkten auf der Pareto-Front dominiert. Dieser Effekt lässt sich durch das schlechte Extrapolationsverhalten des reinen Gauß-Kerns erklären. Mit fortschreitendem Kurzschlussfehler und der daraus resultierenden größeren Spannungsdifferenz werden die Spannungswerte fälschlicherweise wieder als fehlerfrei bewertet (siehe Abschnitt 4.5.3). Dieses unerwünschte Verhalten reduziert eine größere Wahl von  $\sigma$ . Allerdings tritt der beschriebene Effekt dann wieder bei noch größeren Spannungsdifferenzen auf. Erst eine Wahl von  $\omega_{\text{gauss}} < 1$  führt zu einem robusten Verhalten bei beliebig großen Spannungsunterschieden. Umgekehrt ist der rein lineare Kern ( $\omega_{\text{gauss}} = 0$ ) mit einer  $\text{MDR}_{\text{test}} = 87.74$  und  $\text{FAR}_{\text{test}} = 0.17$  ebenfalls nicht Pareto-optimal. Da die Wahl von  $\sigma$  im Fall  $\omega_{\text{gauss}} = 0$  keinen Einfluss auf die Detektionsperformance hat, liegen die Punkte für alle  $\sigma$  übereinander. Somit wird sowohl eine Wahl von  $\omega_{\text{gauss}} = 1$  als auch die Wahl von  $\omega_{\text{lin}} = 1$  von Punkten auf der Pareto-Front dominiert. Dies bestätigt, dass ein echt gemischter Kern ( $0 < \omega_{\text{gauss}}, \omega_{\text{lin}} < 1$ ) den Einzel-Kernen überlegen ist.

Im Allgemeinen trägt ein größerer Kernel-Parameter  $\sigma$  zu einer kleineren FAR und einer höheren MDR bei, und umgekehrt. Das Plateau in den Abbildungen 4.42 und 4.43 äußert sich in Abbildung 4.44 durch eine hohe Dichte an Punkten im Bereich  $40 < \text{MDR}_{\text{test}} < 50$  und  $0.1 < \text{FAR}_{\text{test}} < 0.4$ . Dies bestätigt die geringe Empfindlichkeit der Methode gegenüber Parameteränderungen in  $\omega_{\text{gauss}}$  und  $\sigma$  für nicht extreme Parameterwerte. Das Plateau weist generell eine niedrige FAR und MDR auf. Basierend auf dieser Abschätzung der Sensitivität werden die Parameter  $\sigma = 20.3$  und  $\omega_{\text{gauss}} = 0.55$  gewählt.

### 4.5.9 Fehlerisolation

Wie Abschnitt 1.3 beschreibt, besteht der nächste Schritt nach der Detektion eines Fehlers im Batteriesystem in der Isolation des Fehlers. Die Fehlerisolierung bezieht sich auf die Lokalisierung des Fehlers, so dass der erkannte Fehler mit einer bestimmten Zelle in Verbindung gebracht werden kann. Während für die lineare PCA Ansätze zur expliziten Berechnung der Fehlerbeiträge existieren (siehe Abschnitt 4.4.3), ist die Berechnung der Variablen-Beiträge für die KPCA herausfordernder. Es ist schwierig oder sogar unmöglich, eine inverse Abbildungsfunktion  $\Phi^{-1}(\mathbf{j})$  zu finden, die aus dem hochdimensionalen Merkmalsraum  $\mathbb{F}$  in den Eingangsraum  $\mathbb{R}^m$  transformiert. Unter Verwendung des Lagrangeschen Mittelwertsatzes haben Deng und Tian jedoch einen Ansatz für Gauß-Kerne vorgestellt, um die Beiträge der einzelnen Variablen zu schätzen [50]. Die vorliegende Arbeit erweitert dieses Verfahren, um die Beiträge der einzelnen Variablen sowohl für die Kernel-Funktionen aus Abschnitt 4.5.3 als auch gemischte Kerne zu berechnen.

Sei  $F(\mathbf{z}_t) \in \{T^2(\mathbf{z}_t), Q(\mathbf{z}_t)\}$  eine der beiden in Gleichung (4.228) beziehungsweise (4.229)



eingeführten Teststatistiken  $T^2$  oder  $Q$ . Für die Teststichprobe  $\mathbf{z}_t = [z_{t1} \dots z_{tc} \dots z_{tm}]^T \in \mathbb{R}^m$  zum Zeitpunkt  $t$  folgt gemäß dem Lagrangeschen Mittelwertsatz:

$$F(\mathbf{z}_t) - F(\mathbf{z}_t^0) = \sum_{j=1}^m (z_{tc} - z_{tc}^0) \frac{\partial}{\partial z_{tc}} F(\mathbf{z}_t^0 + \theta (\mathbf{z}_t - \mathbf{z}_t^0)) \quad (4.266)$$

mit dem Parameter  $0 < \theta < 1$  [50]. Wählt man ohne Verlust der Allgemeinheit  $\mathbf{z}_t^0 = \mathbf{0}$ , vereinfacht sich (4.266) gemäß:

$$F(\mathbf{z}_t) = F(\mathbf{0}) + \sum_{c=1}^m z_{tc} \frac{\partial}{\partial z_{tc}} F(\theta \mathbf{z}_t). \quad (4.267)$$

Betrachtet man (4.267), setzt sich  $F(\mathbf{z}_t)$  aus einer Konstanten  $F(\mathbf{0})$  und einem Beitrag zusammen, der sich einer der  $m$  Variablen zuordnen lässt. Der Beitrag der  $c$ -ten Variablen zur Teststatistik  $F(\mathbf{z}_t)$  lässt sich also als

$$C_F(z_{tc}) = z_{tc} \frac{\partial}{\partial z_{tc}} F(\theta \mathbf{z}_t) \quad (4.268)$$

formulieren. Im linearen Fall gilt  $F(\mathbf{0}) = 0$  und, aufgrund der quadratischen Form von (4.167) und (4.168) im linearen Fall,

$$F(\mathbf{z}_t) = \sum_{c=1}^m z_{tc} \frac{\partial}{\partial z_{tc}} F(\theta \mathbf{z}_t) = \theta^2 \sum_{c=1}^m z_{tc} \frac{\partial}{\partial z_{tc}} F(\mathbf{z}_t) = 2\theta^2 F(\mathbf{z}_t), \quad (4.269)$$

woraus direkt der konstante Parameter  $\theta = \frac{1}{\sqrt{2}}$  resultiert [50]. Im nichtlinearen Fall hingegen müsste  $\theta$  für jedes Sample  $\mathbf{z}_t$  neu berechnet werden oder ein geeignetes gemeinsames  $\theta$  anhand der Trainingsdaten gefunden werden. Für die Anwendung zur ISC-Detektion liefert jedoch bereits die Wahl der Konstanten  $\theta = \frac{1}{\sqrt{2}}$ , wie im linearen Fall, sehr gute Ergebnisse. Zur übersichtlicheren Notation erfolgt die Berechnung der Beiträge an dieser Stelle mit der vollen Kernel-Matrix  $\mathbf{K}$ . Die Berechnung mit der Approximation  $\widehat{\mathbf{K}} \approx \mathbf{K}$  resultiert direkt durch Ersetzen von  $\mathbf{K}$  durch  $\widehat{\mathbf{K}}$ . Mit

$$T^2(\mathbf{z}_t) = \mathbf{t}_t^T \mathbf{\Lambda}_{\text{pc}}^{-1} \mathbf{t}_t = \mathbf{k}_t^T \mathbf{S}_{\text{pc}} \mathbf{\Lambda}_{\text{pc}}^{-1} \mathbf{S}_{\text{pc}}^T \mathbf{k}_t, \quad (4.270)$$

lässt sich der Beitrag des  $c$ -ten Signals zur  $T^2$ -Teststatistik für Testdaten  $\mathbf{z}_t$  berechnen:

$$\begin{aligned} C_{T^2}(z_{tc}) &= z_{tc} \frac{\partial}{\partial z_{tc}} \left( \mathbf{k}_t^T \mathbf{S}_{\text{pc}} \mathbf{\Lambda}_{\text{pc}}^{-1} \mathbf{S}_{\text{pc}}^T \mathbf{k}_t \right) \Big|_{\theta \mathbf{z}_t} \\ &= 2z_{tc} \frac{\partial \mathbf{k}_t^T}{\partial z_{tc}} \mathbf{S}_{\text{pc}} \mathbf{\Lambda}_{\text{pc}}^{-1} \mathbf{S}_{\text{pc}}^T \mathbf{k}_t \Big|_{\theta \mathbf{z}_t}. \end{aligned} \quad (4.271)$$

Analog dazu folgt mit

$$Q_t = \mathbf{k}_t^T \mathbf{k}_t - \mathbf{t}_t^T \mathbf{t}_t = \mathbf{k}_t^T (\mathbf{I} - \mathbf{S}_{\text{pc}} \mathbf{S}_{\text{pc}}^T) \mathbf{k}_t \quad (4.272)$$

für den Beitrag der  $c$ -ten Variablen zur  $Q$ -Statistik:

$$\begin{aligned} C_Q(z_{tc}) &= z_{tc} \frac{\partial}{\partial z_{tc}} \left( \mathbf{k}_t^T (\mathbf{I} - \mathbf{S}_{\text{pc}} \mathbf{S}_{\text{pc}}^T) \mathbf{k}_t \right) \Big|_{\theta \mathbf{z}_t} \\ &= 2z_{tc} \frac{\partial \mathbf{k}_t^T}{\partial z_{tc}} (\mathbf{I} - \mathbf{S}_{\text{pc}} \mathbf{S}_{\text{pc}}^T) \mathbf{k}_t \Big|_{\theta \mathbf{z}_t}, \end{aligned} \quad (4.273)$$

wobei

$$\frac{\partial \mathbf{k}_t}{\partial z_{tc}} \Big|_{\theta \mathbf{z}_t} = \left[ \frac{\partial \kappa(\theta \mathbf{z}_t, \mathbf{z}_1)}{\partial z_{tc}} \dots \frac{\partial \kappa(\theta \mathbf{z}_t, \mathbf{z}_\tau)}{\partial z_{tc}} \dots \frac{\partial \kappa(\theta \mathbf{z}_t, \mathbf{z}_N)}{\partial z_{tc}} \right]^T \quad (4.274)$$

für  $\tau \in [1, N]$  ist.  $\mathbf{k}_t$  entspricht dem gemäß (4.225) zentrierten Kernel-Vektor:

$$\begin{aligned} \kappa(\theta \mathbf{z}_t, \mathbf{z}_\tau) &= \tilde{\kappa}(\theta \mathbf{z}_t, \mathbf{z}_\tau) - \frac{1}{N} \sum_{i=1}^N \tilde{\kappa}(\theta \mathbf{z}_t, \mathbf{z}_i) \\ &\quad - \frac{1}{N} \sum_{j=1}^N \tilde{\kappa}(\mathbf{z}_j, \mathbf{z}_\tau) + \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \tilde{\kappa}(\mathbf{z}_i, \mathbf{z}_j). \end{aligned} \quad (4.275)$$

Für die partielle Ableitung von  $\kappa(\theta \mathbf{z}_t, \mathbf{z}_\tau)$  nach  $z_{tc}$  gilt

$$\begin{aligned} \frac{\partial \kappa(\theta \mathbf{z}_t, \mathbf{z}_\tau)}{\partial z_{tc}} &= \frac{\partial \tilde{\kappa}(\theta \mathbf{z}_t, \mathbf{z}_\tau)}{\partial z_{tc}} - \frac{1}{N} \sum_{i=1}^N \frac{\partial \tilde{\kappa}(\theta \mathbf{z}_t, \mathbf{z}_i)}{\partial z_{tc}} \\ &\quad - \frac{1}{N} \sum_{j=1}^N \frac{\partial \tilde{\kappa}(\mathbf{z}_j, \mathbf{z}_\tau)}{\partial z_{tc}} + \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \frac{\partial \tilde{\kappa}(\mathbf{z}_i, \mathbf{z}_j)}{\partial z_{tc}}. \end{aligned} \quad (4.276)$$

Da die letzten beiden Terme von (4.276) keine Abhängigkeit von  $z_{tc}$  haben, gilt

$$\frac{\partial \tilde{\kappa}(\mathbf{z}_j, \mathbf{z}_\tau)}{\partial z_{tc}} = \frac{\partial \tilde{\kappa}(\mathbf{z}_i, \mathbf{z}_j)}{\partial z_{tc}} = 0 \quad \forall \tau, i, j. \quad (4.277)$$

Durch die Verwendung des gemischten Kerns (4.246) ergibt sich

$$\frac{\partial \kappa(\theta \mathbf{z}_t, \mathbf{z}_\tau)}{\partial z_{tc}} = \sum_{l=1}^{N_{\text{ker}}} \omega_l \frac{\partial \tilde{\kappa}_l(\theta \mathbf{z}_t, \mathbf{z}_\tau)}{\partial z_{tc}} - \frac{1}{N} \sum_{i=1}^N \sum_{l=1}^{N_{\text{ker}}} \omega_l \frac{\partial \tilde{\kappa}_l(\theta \mathbf{z}_t, \mathbf{z}_i)}{\partial z_{tc}}. \quad (4.278)$$

Die Ableitungen  $\frac{\partial \tilde{\kappa}_l(\theta \mathbf{z}_t, \mathbf{z}_\tau)}{\partial z_{tc}}$  und analog die Ableitungen  $\frac{\partial \tilde{\kappa}_l(\theta \mathbf{z}_t, \mathbf{z}_i)}{\partial z_{tc}}$  ergänzt Tabelle 4.6 für verschiedene Kernel-Funktionen. Für den in dieser Arbeit genutzten gemischten Kern



**Tabelle 4.6:** Partielle Ableitungen  $\frac{\partial}{\partial z_{tc}} \tilde{\kappa}(\theta \mathbf{z}_t, \mathbf{z}_\tau)$  der Kernel-Funktionen aus Abschnitt 4.5.3 zur Berechnung der Variablen-Beiträge.

---

$\frac{\partial}{\partial z_{tc}} \tilde{\kappa}_{\text{lin}}(\theta \mathbf{z}_t, \mathbf{z}_\tau) = \theta z_{\tau c}$
$\frac{\partial}{\partial z_{tc}} \tilde{\kappa}_{\text{poly}}(\theta \mathbf{z}_t, \mathbf{z}_\tau) = d \theta z_{\tau c} (\theta \mathbf{z}_t^T \mathbf{z}_\tau + \text{const})^{d-1}$
$\frac{\partial}{\partial z_{tc}} \tilde{\kappa}_{\text{gauss}}(\theta \mathbf{z}_t, \mathbf{z}_\tau) = -\frac{\theta}{\sigma^2} (\theta z_{tc} - z_{\tau c}) \exp\left(-\frac{1}{2\sigma^2} \ \theta \mathbf{z}_t - \mathbf{z}_\tau\ ^2\right)$
$\frac{\partial}{\partial z_{tc}} \tilde{\kappa}_{\text{rq}}(\theta \mathbf{z}_t, \mathbf{z}_\tau) = 2c \theta (\theta z_{tc} - z_{\tau c}) (\ \theta \mathbf{z}_t - \mathbf{z}_\tau\ ^2 + \text{const})^{-2}$
$\frac{\partial}{\partial z_{tc}} \tilde{\kappa}_{\text{imult}}(\theta \mathbf{z}_t, \mathbf{z}_\tau) = -\theta (\theta z_{tc} - z_{\tau c}) (\ \theta \mathbf{z}_t - \mathbf{z}_\tau\ ^2 + \text{const}^2)^{-1.5}$
$\frac{\partial}{\partial z_{tc}} \tilde{\kappa}_{\text{cauchy}}(\theta \mathbf{z}_t, \mathbf{z}_\tau) = -\frac{2\theta}{\sigma^2} (\theta z_{tc} - z_{\tau c}) \left(1 + \frac{1}{\sigma^2} \ \theta \mathbf{z}_t - \mathbf{z}_\tau\ ^2\right)^{-2}$
$\frac{\partial}{\partial z_{tc}} \tilde{\kappa}_{\text{tstud}}(\theta \mathbf{z}_t, \mathbf{z}_\tau) = -d \theta (\theta z_{tc} - z_{\tau c}) \ \theta \mathbf{z}_t - \mathbf{z}_\tau\ ^{d-2} (1 + \ \theta \mathbf{z}_t - \mathbf{z}_\tau\ ^d)^{-2}$

---

$$\begin{aligned} \tilde{\kappa}(\theta \mathbf{z}_t, \mathbf{z}_\tau) &= \omega_1 \tilde{\kappa}_{\text{lin}}(\theta \mathbf{z}_t, \mathbf{z}_\tau) + \omega_2 \tilde{\kappa}_{\text{gauss}}(\theta \mathbf{z}_t, \mathbf{z}_\tau) \\ &= \omega_1 \left( \theta \mathbf{z}_t^T \mathbf{z}_\tau + \text{const} \right) + \omega_2 \exp\left(-\frac{1}{2\sigma^2} \|\theta \mathbf{z}_t - \mathbf{z}_\tau\|^2\right), \end{aligned} \quad (4.279)$$


der aus einer Kombination des linearen und des Gauß-Kerns besteht, folgt

$$\begin{aligned} \frac{\partial \kappa(\theta \mathbf{z}_t, \mathbf{z}_\tau)}{\partial z_{tc}} &= \omega_1 \theta \left( z_{\tau c} - \frac{\theta z_{tc} - z_{\tau c}}{\sigma^2} \exp\left(-\frac{1}{2\sigma^2} \|\theta \mathbf{z}_t - \mathbf{z}_\tau\|^2\right) \right) \\ &\quad - \frac{\omega_2 \theta}{N} \sum_{i=1}^N \left( z_{ic} - \frac{\theta z_{tc} - z_{ic}}{\sigma^2} \exp\left(-\frac{1}{2\sigma^2} \|\theta \mathbf{z}_t - \mathbf{z}_i\|^2\right) \right). \end{aligned} \quad (4.280)$$


Unter Verwendung der allgemeinen Gleichung (4.278) oder der Gleichung (4.280) für den gewählten gemischten Kern lassen sich mit (4.271) und (4.273) die Beiträge zur  $T^2$ - und  $Q$ -Statistik der  $c$ -ten Variablen zur  $t$ -ten Stichprobeninstanz berechnen.

### Experimentelle Validierung der Fehlerisolation

Die Fehlerdetektion und -isolation sowie die effiziente Wahl der Trainingsdaten (siehe Abschnitt 4.5.7) validiert dieser Abschnitt anhand des SMG-Modulprüfstands (siehe Abschnitt 4.2.3) mit unterschiedlichen Kurzschlusswiderständen. Dazu kommen zunächst fehlerfreie Messdaten zum Einsatz, um das Monitoring-Verhalten in Abwesenheit von Fehlern zu validieren. Abbildung 4.45 zeigt die Werte der  $T^2$ - und  $Q$ -Statistiken sowie das UCL basierend auf einer Kerndichteschätzung mit einer Konfidenz von 99 %. Das Training erfolgt in den ersten 16 h, der Test beginnt für  $t > 16$  h. Die ausgewählte Trainingsuntermenge hat eine Kardinalität von  $n = 257$  bei einer Toleranz von  $\eta = 10^{-3}$ . Die von Algorithmus ausgewählten Trainingspunkte sind in blau markiert. Zusätzlich zeigt Abbildung 4.45 ergänzend die Werte der beiden Teststatistiken für die verbleibenden Trainingspunkte sowie die Ergebnisse




**Abbildung 4.45:** Resultierende  $T^2$ - und  $Q$ -Statistik nach Anwendung der KPCA-basierten Überwachung mit optimaler Trainingsdatenwahl ( $\eta = 10^{-3}$ ) auf den fehlerfreien SMG-Datensatz.




**Abbildung 4.46:** Beitragsdiagramm der Zellspannungen zur  $T^2$ - und  $Q$ -Statistik für verschiedene Zeiträume während der KPCA-basierten Überwachung (Abbildung 4.45) der fehlerfreien SMG-Zellen.

während des Tests (rot). Die FARs betragen  $\text{FAR}_{\text{train}} = 0.12\%$  und  $\text{FAR}_{\text{test}} = 0.23\%$ . In den Statistiken ist, auch ohne ein adaptives Verfahren (siehe Abschnitt 4.4.4), kein signifikanter Drift zu beobachten. Abbildung 4.46 zeigt die nach Abschnitt 4.5.9 berechneten Beiträge für verschiedene Zeiträume während des Trainings, während des Tests ohne Fehler und während des Tests mit ISC. Die Beitragsdiagramme zeigen den Beitrag jeder Variable




**Abbildung 4.47:** Resultierende  $T^2$ - und  $Q$ -Statistik nach Anwendung der KPCA-basierten Überwachung mit optimaler Trainingsdatenwahl ( $\eta = 10^{-3}$ ) den SMG-Datensatz für den Fall  $R_{\text{ISC}} = 10 \Omega$ .




**Abbildung 4.48:** Beitragsdiagramm der Zellspannungen zur  $T^2$ - und  $Q$ -Statistik für verschiedene Zeiträume während der KPCA-basierten Überwachung (Abbildung 4.45) der SMG-Zellen für den Fall  $R_{\text{ISC}} = 10 \Omega$ .

zur  $T^2$ - beziehungsweise  $Q$ -Statistik. Jeder Balken entspricht einer der  $m = 12$ -Zellen. Der Durchschnitt der Beiträge ist im Training auf 1 normalisiert. Für die weiteren Perioden nach dem Training ist keine signifikante Änderung in den Testdaten zu beobachten, was dem gewünschten Verhalten im fehlerfreien Fall entspricht.

Die Abbildungen 4.47, 4.49, 4.51 und 4.53 zeigen die Ergebnisse für die Fehlerfälle  $R_{\text{ISC}} \in \{10 \Omega, 100 \Omega, 1 \text{ k}\Omega, 10 \text{ k}\Omega\}$ . Bevor der ISC zum Zeitpunkt  $t = 0 \text{ h}$  auftritt, gekennzeichnet




**Abbildung 4.49:** Resultierende  $T^2$ - und  $Q$ -Statistik nach Anwendung der KPCA-basierten Überwachung mit optimaler Trainingsdatenwahl ( $\eta = 10^{-3}$ ) den SMG-Datensatz für den Fall  $R_{\text{ISC}} = 100 \Omega$ .




**Abbildung 4.50:** Beitragsdiagramm der Zellspannungen zur  $T^2$ - und  $Q$ -Statistik für verschiedene Zeiträume während der KPCA-basierten Überwachung (Abbildung 4.45) der SMG-Zellen für den Fall  $R_{\text{ISC}} = 100 \Omega$ .

durch eine gestrichelte Linie, werden 16 h Training und 8 h Validierung durchgeführt. Die Anzahl der Punkte, die der Algorithmus zur Approximation des Merkmalsraums mit einer Toleranz von  $\eta = 10^{-3}$  wählt, reicht von  $n = 252$  bis  $n = 357$ . Dies entspricht 0.19 % bis 0.38 % der Größe der vollen Kernel-Matrix, was eine signifikante Reduktion der Berechnungs- und Speicherkomplexität bedeutet. Die FARs im Training und Test reichen von 0.14 % bis 0.19 %. Die DT hängt vom Ausmaß des ISCs ab. Kleinere Widerstände erzeugen schneller




**Abbildung 4.51:** Resultierende  $T^2$ - und  $Q$ -Statistik nach Anwendung der KPCA-basierten Überwachung mit optimaler Trainingsdatenwahl ( $\eta = 10^{-3}$ ) den SMG-Datensatz für den Fall  $R_{\text{ISC}} = 1 \text{ k}\Omega$ .




**Abbildung 4.52:** Beitragsdiagramm der Zellspannungen zur  $T^2$ - und  $Q$ -Statistik für verschiedene Zeiträume während der KPCA-basierten Überwachung (Abbildung 4.45) der SMG-Zellen für den Fall  $R_{\text{ISC}} = 1 \text{ k}\Omega$ .

eine hohe Spannungsdifferenz, siehe Abbildung 4.11. Das in Abschnitt 4.5.5 eingeführte Detektionsmaß nimmt den Wert 1 an, wenn beide Statistiken oberhalb ihrer UCL liegen und ist ansonsten 0. Das Maß wird zeitlich durch ein gleitendes Mittelwertfilter mit einem Zeitfenster von 200 Abtastwerten gefiltert, was 0.56 h entspricht. Überschreitet das Maß einen Schwellenwert von 0.5, so gilt der Fehler als erkannt. Das gleitende Mittelwertfilter verlängert die DT, verhindert aber unerwünschte Fehlalarme. Kleine Kurzschlusswiderstände



**Abbildung 4.53:** Resultierende  $T^2$ - und  $Q$ -Statistik nach Anwendung der KPCA-basierten Überwachung mit optimaler Trainingsdatenwahl ( $\eta = 10^{-3}$ ) den SMG-Datensatz für den Fall  $R_{\text{ISC}} = 10 \text{ k}\Omega$ .



**Abbildung 4.54:** Beitragsdiagramm der Zellspannungen zur  $T^2$ - und  $Q$ -Statistik für verschiedene Zeiträume während der KPCA-basierten Überwachung (Abbildung 4.45) der SMG-Zellen für den Fall  $R_{\text{ISC}} = 10 \text{ k}\Omega$ .

sind auch an der reinen Spannungsdifferenz oder, bei noch weiter fortgeschrittenen ISCs, an einer Temperaturerhöhung zu erkennen.

Die zugehörigen Beitragsdiagramme zeigen die Abbildungen 4.48, 4.50, 4.52 und 4.54. Links der gestrichelten Linie ist ein Zeitraum während des Trainings ( $-20 \text{ h} < t < -16 \text{ h}$ ) und ein Zeitraum während der Validierungsphase ( $-8 \text{ h} < t < -4 \text{ h}$ ) dargestellt. Die beiden Zeiträume rechts von der gestrichelten Linie werden nach der ISC-Emulation gewählt. Die

auffällige Zelle, für die eine ISC bei  $t = 0$  h emuliert wird, ist rot hervorgehoben. Wie in Abbildung 4.46 ist vor dem Auftreten des Fehlers kein signifikanter Beitrag einer einzelnen Zelle zu den jeweiligen Statistiken zu beobachten. Nach dem Auftreten des ISCs dominiert jedoch stets die fehlerhafte Zelle die Beiträge zu den jeweiligen Statistiken. Obwohl der Algorithmus im Fall  $R_{\text{ISC}} = 10 \text{ k}\Omega$  den Fehler erst nach 12.23 h erkennt, ist der Beitrag der fehlerhaften Zelle bereits im Zeitraum  $-8 \text{ h} < t < -4 \text{ h}$  signifikant. Zelle 10 zeigt in diesem Zeitraum bereits den 5.65-fachen Beitrag zur  $T^2$ -Statistik und den 2.95-fachen Beitrag zur  $Q$ -Statistik im Vergleich zum nächstgrößeren Beitrag von Zelle 7 beziehungsweise Zelle 5. Dies bestätigt, dass sich die in Abschnitt 4.5.9 vorgestellte Methode erfolgreich auf gemischte Kerne anwenden lässt und die resultierenden Beitragsdiagramme geeignet sind, fehlerhafte Zellen zu isolieren.

Außerdem ist in den Beitragsdiagrammen zu beobachten, dass sich nach dem Auftreten des Fehlers der Beitrag der fehlerfreien Zellen zur  $T^2$ -Statistik zunehmend verringert und sich die Beiträge zur  $Q$ -Statistik vergrößern. Nach Slišković, Grbić und Hocenski korrespondiert die  $T^2$ -Statistik mit den systematischen Variationen in den Trainingsdaten [266]. Die  $Q$ -Statistik hingegen überwacht den unsystematischen Anteil in den Trainingsdaten. Sie wird daher mit dem Rauschen oder besonderen Ereignissen in den Testdaten assoziiert. Nach dem Auftreten des Fehlers entspricht das Verhalten der Spannungssignale nicht mehr dem gelernten Datenmodell, weshalb die mittleren Beiträge zur  $T^2$ -Statistik sinken und die mittleren Beiträge zur  $Q$ -Statistik steigen.

## 4.6 Ergebnisse und Fazit zur datengetriebenen Diagnose interner Kurzschlüsse

Für die Anwendung von Algorithmen zur Diagnose interner Kurzschlüsse hat sich gezeigt, dass besonders die Spannungsunterschiede zwischen den Zellen ein sehr aussagekräftiges Merkmal sind. Die Spannungsdifferenzen können als Residuen betrachtet werden, bei denen die übrigen Zellen des Systems das Referenzmodell bilden. In Batteriesystemen ist üblicherweise eine hohe Homogenität erwünscht, weshalb in der Regel Zellen aus einer Charge innerhalb eines Batteriepacks zum Einsatz kommen. Selbst in gealterten Batteriepacks, nahe am Ende des Lebenszyklus, existiert deshalb zu jeder Zelle eine Vergleichszelle, die die betreffende Zelle mit einem Spannungs-RMSE von weniger als 3 mV beschreibt. Für größere und homogenere Batteriepacks liegt für die Mehrheit der Zellen eine ähnliche Zelle mit einem Spannungsverlauf vor, der sich lediglich mit einem RMSE von 0.5 mV unterscheidet (siehe Abschnitt 4.2). Da diese Genauigkeit über den gesamten SOC-, Temperatur- und Alterungsbereich mit modellbasierten Methoden nicht oder nur mit erheblichem Modellierungsaufwand erreichbar ist, motiviert dies den Einsatz von datengetriebenen Verfahren, die die Spannungsunterschiede analysieren.

Die Aussagekraft der Spannungsdifferenzen unterstreicht bereits der Einsatz des linearen PCA-basierten Monitoring-Verfahrens mit dem sich erfolgreich Anomalien auf Basis eines vorangegangenen Trainings detektieren lassen. Die Detektion basiert auf zwei statistischen Maßen, der  $T^2$ - und  $Q$ -Statistik. Während sich mit der  $T^2$ -Statistik Abweichungen vom gelernten Datenmodell detektieren lassen, lässt sich mit der  $Q$ -Statistik eine Änderung in der Verteilung des unsystematischen Rauschens detektieren. Die Analyse des Beitrags, den die inhärent mit den Zellen verknüpften Variablen zu den Kontrollstatistiken beitragen, erlaubt eine Fehlerisolation. Da sich die Betriebsbedingungen und Zellparameter von Batteriesystemen über die Lebensdauer hinweg kontinuierlich ändern, thematisiert die vorliegende Arbeit auch ein nicht-stationäres Verhalten der Anwendung. Eine beschleunigte Alterungssimulation verringert die Zellkapazitäten und erhöht die Zellinnenwiderstände, während gleichzeitig die Variationen der Zellparameter ansteigen. Die RPCA und die MWPCA adaptieren das gelernte Datenmodell kontinuierlich, sodass die entwickelten Verfahren in der Lage sind, eine Änderung in der Verteilung der fehlerfreien Trainingsdaten zu lernen.

Das lineare Zellmonitoring nimmt an, dass die Residuen, also die Zellspannungsdifferenzen, multivariat Gauß-verteilt sind und linear variieren. Während diese Annahme auf homogene Batteriesysteme annähernd zutrifft, ist sie im Falle von gealterten Batteriesystemen mit größeren Parametervariationen nicht mehr erfüllt (siehe Abschnitt 4.3.2). Obwohl auch hier das lineare Monitoring noch eine robuste Detektion größerer Fehler liefert, verspricht eine bessere Approximation der zugrundeliegenden Verteilung eine höhere Sensitivität. Die Anwendung der nichtlinearen KPCA approximiert die Datenverteilung mit einem Gauß-Kern. Eine detaillierte Analyse zeigt jedoch, dass der Gauß-Kern mit einem linearen Kern kombiniert werden sollte, um ein robustes Extrapolationsverhalten im Falle weiter fortgeschrittener ISCs zu erhalten. Entsprechend ist die Detektionsperformance der linearen und der nichtlinearen Methode im Falle schnell anwachsender Fehler, wie beispielsweise einem emuliertem  $10\ \Omega$ -ISC an einer 25 Ah-Zelle, vergleichbar. Die höhere Sensitivität gegenüber beginnenden, frühen Anomalien in den Eingangsdaten ermöglicht jedoch im Falle kleiner ISCs ( $100\ \Omega$ -ISC an einer 25 Ah-Zelle) eine Halbierung der Detektionszeit der KPCA-basierten Methode im Vergleich zum linearen PCA-basierten Monitoring. Der Vergleich mit bekannten Methoden aus der Literatur zeigt, dass bereits das lineare PCA-basierte Monitoring ISCs schneller detektiert als die Vergleichsmethoden.

Das nichtlineare Monitoring geht, verglichen mit den linearen Verfahren, mit einem höheren Rechenaufwand einher. Während die für das lineare Monitoring berechnete quadratische Kovarianzmatrix die Dimension  $m$  der Eingangsvariablen hat, besitzt die quadratische Gram-Matrix im nichtlinearen Fall die Dimension  $N$  der Anzahl der Stichproben. Eine Analyse der Verteilung im hochdimensionalen Merkmalsraum zeigt jedoch, dass die projizierten Vektoren lineare Abhängigkeiten besitzen. Der resultierende Unterraum lässt sich deshalb auch mit einer Untermenge  $n \ll N$  an Trainingsdaten aufspannen. Eine weitere Reduktion ergibt eine Approximation der Gram-Matrix bis zu einer gewünschten Genauigkeit. Mit



steigender Zellanzahl, also steigender Anzahl der Eingangssignale, reduzieren sich jedoch die linearen Abhängigkeiten, sodass eine größere Teilmenge an Trainingsamples für die Matrix-Approximation bei identischer Genauigkeit erforderlich ist (*Fluch der Dimensionalität*). Eine Wahl von  $n = m$  Trainingsdaten garantiert jedoch mindestens die Performance der linearen Methode. Die optimale Wahl der Parameter resultiert in einer Pareto-Optimierung zwischen der FAR und der MDR. Dabei zeigt sich, dass nur Kombinationen aus der linearen und der auf dem Gauß-Kern basierten Methode optimal sind. Die Detektionsperformance, also der Kompromiss aus FAR und MDR, ist dabei abseits von extrem gewählten Parametern (rein linear, rein Gauß oder sehr kleiner Gauß-Kern) robust. Die zur Fehlerisolation entwickelte Beitragsanalyse für gemischte Kerne ermöglicht die Lokalisierung der fehlerhaften Zelle. Die optimierte, nichtlineare Methode erlaubt die Detektion eines emulierten  $10\text{ k}\Omega$ -ISCs in einem 12s1p-Modul, bestehend aus 2.5 Ah-Zellen, nach 12.23 h. In den Beiträgen zu den Kontrollstatistiken sind jedoch schon im Zeitraum  $t \in [4\text{ h}, 8\text{ h}]$  nach Emulation des ISCs signifikante Anteile der fehlerhaften Zelle erkennbar.

In Anbetracht des vorgesehenen Einsatzes in Elektrofahrzeugbatterien ist die Methode in allen Betriebsphasen anwendbar, das heißt, während des Ladens, des dynamischen Entladens und im Ruhezustand. Nach dem Balancieren der Zellen ist jedoch eine Aktualisierung des Datenmodell erforderlich. Passives Balancieren, beispielsweise, ähnelt der ISC-Emulationsmethode, so dass das Monitoring während dieser Phase ausgesetzt werden müsste. Die Aktualisierung des Datenmodell kann beispielsweise über den rekursiven oder fensterbasierten Ansatz aus Abschnitt 4.4.4 erfolgen.



## 5 Aktive modellbasierte Fehlerdiagnose zur erweiterten Fehlerisolation

Während die modellbasierte Fehlerdiagnose in herkömmlichen Batteriesystemen ein weit erforschtes Gebiet ist, stellen RBSs ein relativ junges Forschungsthema dar. Eine Analyse des Stands der Technik in Abschnitt 5.1 offenbart, dass insbesondere die aktive Fehlerdiagnose in RBSs ein neues Forschungsgebiet ist. Der aktiven Diagnose geht eine strukturelle Analyse voran, die bereits ohne Parametrierung einen Einblick in das zugrundeliegende System ermöglicht. Basierend auf dem in Abschnitt 5.2 vorgestellten Modell eines RBS-Moduls, findet die strukturelle Analyse in Abschnitt 5.3 eine minimale Sensormenge mit optimaler Fehlerisolierbarkeit. Die Generierung von Residuen zur Fehlerdiagnose in RBSs mithilfe der Theorie der strukturellen Analyse ist jedoch herausfordernd, da RBSs über eine Vielzahl an Gleichungen verfügen und eine Veränderung der Systemstruktur die Berücksichtigung von Validitätsbedingungen für jede Gleichung erfordert. Um diese Herausforderung anzugehen, entwickelt Abschnitt 5.3 einen neuen Algorithmus zum Finden von minimal strukturell überbestimmten (Minimal-Structurally-Overdetermined, MSO) Teilmengen in Systemen mit vielen Gleichungen und einer hohen Redundanz. Abschnitt 5.4 stellt die aus den gefundenen MSO-Teilsystemen resultierenden Residuen sowie den experimentellen Versuchsaufbau vor, an dem der entwickelte Algorithmus validiert wird. Eine Komplexitätsanalyse vergleicht den Rechenaufwand des neuen Ansatzes mit bekannten Methoden am Beispiel konventioneller und rekonfigurierbarer Batteriesysteme. Basierend auf den gefundenen Residuen führt Abschnitt 5.5 ein beschränktes SPKF ein, das innerhalb des in Abschnitt 5.6 vorgestellten Frameworks die Modellparameter an das reale System anpasst und in der Lage ist, die Fehleramplituden zu schätzen. Neben einer passiven Fehlerdetektion und -isolation führt Abschnitt 5.6 ein Detektierbarkeitsmaß für strukturell, aber nicht analytisch beobachtbare Fehler ein und stellt den aktiven Isolationsansatz, basierend auf einem aktiven Hypothesentest, vor. Eine anschließende Validierung am experimentellen RBS-Modul zeigt das erweiterte Isolationsvermögen des aktiven Ansatzes und validiert das Framework anhand zweier exemplarischer Fehler (Abschnitt 5.7).

Die Beiträge dieses Kapitels basieren auf den Veröffentlichungen [237, 238].

## 5.1 Stand der Technik

Mit den in Abschnitt 2.1.3 beschriebenen Vorteilen rekonfigurierbarer Batteriesysteme geht auch eine größere Anzahl an Komponenten einher. Neben den Zellen sind im Batteriepack auch Schalter und ein gesteigerter Umfang an Elektronik vorhanden. Mit zunehmender Anzahl der Komponenten vergrößert sich jedoch auch die Wahrscheinlichkeit, dass eine der Komponenten ausfällt. Aus diesem Grund ist besonders in RBSs die Fehlerdiagnose ein wesentlicher Bestandteil des BMSs, um die Robustheit des Systems zu erhöhen. Wie Tabelle 1.1 zeigt, ist die Literatur zu modellbasierten Ansätzen zur Fehlerdiagnose in Batteriesystemen sehr umfangreich. Eine Übersicht über die jüngsten Arbeiten geben Tran und Fowler sowie Hu, Zhang u. a. [123, 278]. Modellbasierte Ansätze vergleichen üblicherweise die Sensormessungen mit Signalen, die ein Systemmodell generiert. Die Abweichungen, sogenannte *Residuen*, werden zur Fehlerdiagnose analysiert. Sowohl Tran und Fowler als auch Hu, Zhang u. a. unterteilen die modellbasierten Methoden basierend auf Zustands- oder Parameterschätzung [262, 264], Parity-Space-Methoden [176, 191] oder strukturelle Analysemethoden [171, 172, 175]. Diese Arbeit unterscheidet zudem zwischen *passiver* und *aktiver* Fehlerdiagnose. Erstere analysiert nur die Messungen des Systems als externer Beobachter, während letztere diese Analyse durch die Wahl von Aktionen auf dem System erweitert, um die Fehlerdiagnose weiter zu verbessern.

Zunächst setzt sich dieser Abschnitt mit dem Stand der Technik im Bereich der passiven, modellbasierten Fehlerdiagnose in Batteriesystemen auseinander. Ein Vorteil der strukturellen Analyse ist die Möglichkeit, unabhängig von den Parameterwerten des Batteriesystems eine Fehlerdetektions- und Isolierbarkeitsanalyse durchzuführen, was den Arbeitsaufwand für die Entwicklung der Residuengenerierung zur Fehlerisolierung erheblich reduziert [123]. Basierend auf der strukturellen Analyse lassen sich MSO-Teilsysteme finden, die sich zur Generierung von Residuen für die Fehlerdiagnose eignen [6, 172]. Liu, Ahmed u. a. wenden die strukturelle Analyse auf einen Batteriepack [171, 175] und auf zylindrische Lithium-Ionen-Zellen [172] an, um Residuen für die Fehlerdiagnose zu erzeugen. In ihren bisherigen Arbeiten betrachten die Autoren jedoch nur Sensorfehler und Kühlsystemfehler in konventionellen Batterien. Zheng, Chen und Huang diagnostizieren Fehler in Spannungs- und Strommessungen mit einem Unscented-Partikelfilter [323]. Dey, Mohon u. a. lösen diese Aufgabe mit Sliding-Mode-Beobachtern, die auf der elektrischen und thermischen Dynamik des Batteriesystems basieren [53]. Um eine robuste Schätzung des *State of Energy* zu erhalten, führen Xu, Wang u. a. eine beobachterbasierte Stromsensor-Fehlerdiagnose durch [306]. Xiong, Yu u. a. detektieren Spannungs- und Stromsensorfehler durch die Differenz zwischen dem wahren Ladezustand und dem geschätzten SOC der einzelnen Zellen [304]. Liu und He schlagen einen Ansatz zur Sensorfehlerdiagnose vor, bei dem ein adaptives EKF die beiden Zellen mit der höchsten und der niedrigsten Spannung beobachtet [174]. Die Annahme der Autoren ist dabei, dass die beiden beobachteten Zellen die Zellen sind, die am wahrscheinlichsten über- oder unterladen

werden. Die Überwachung der restlichen Zellen erfolgt offline mit einem längeren Zeitintervall. Basierend auf einer Systemidentifikation mit der RLS-Methode und einem EKF präsentieren Chen, Xu u. a. einen Ansatz zur Spannungsfehlerdetektion [32]. Ein Maß für die Anomalie, der lokale Ausreißerfaktor, wird berechnet und mit einem Ausreißerfilter basierend auf dem Grubbs-Kriterium evaluiert. Chen, Chen u. a. verwenden einen Luenberger-Beobachter zur Fehlerisolation und -schätzung eines erhöhten Innenwiderstands für ein Batteriesystem mit reiner Serienschaltung [29]. Die vorgenannten Ansätze zur modellbasierten Fehlerdiagnose [29, 32, 53, 172, 174, 304, 306, 323] haben einen oder mehrere der folgenden Nachteile. Sie werden auf eine Einzelzelle [53, 172, 306] oder rein seriell verschaltete Zellen [29, 32, 304] angewandt, wobei angenommen wird, dass sich parallel verschaltete Zellen wie eine große Zelle verhalten. Dies vernachlässigt die Stromverteilung der parallel geschalteten Zellen sowie die Kontakt- und Stromschienenwiderstände. Während die bekannte Literatur oft nur Sensorfehler betrachtet [32, 53, 172, 174, 304, 306, 323], berücksichtigt die vorliegende Arbeit sowohl Sensor- als auch Parameterfehler für eine Verbindung mehrerer Batteriezellen. Keiner der modellbasierten Ansätze wurde auf RBSs angewandt, um neben den Zellfehlern auch Bauteilfehler zu diagnostizieren. Insbesondere ist den vorgestellten modellbasierten Ansätzen gemeinsam, dass sie die Sensormessungen passiv nutzen und das Batteriesystem zur Fehlerdiagnose nicht aktiv rekonfigurieren.

Die Maßnahmen der aktiven Fehlerdiagnoseverfahren können das Hinzufügen eines Diagnosesignals zum System, wie in [198, 220], oder das Ändern der Struktur des Batteriesystems, über die in RBSs vorhandenen Schalter, umfassen. Chen, Lin u. a. sowie Sampath, Lafortune und Teneketzi modellieren ein RBS als Finite-State-Machine [31, 232]. Dies ermöglicht die Entwicklung einer Methode zur aktiven strukturellen Fehlerdiagnose. Beide interpretieren alle möglichen Schaltzustände und alle möglichen Fehler als Zustände der Finite-State-Machine. Obwohl Chen, Lin u. a. nur zwei mögliche Fehler pro Zelle betrachten, führt der Ansatz zu einer exponentiellen Komplexität bezüglich der Anzahl der Zellen [31]. Diese Herausforderung macht ihn ungeeignet für ein großformatiges RBS, dessen Modell aus einer Vielzahl an Gleichungen besteht. Zudem berücksichtigt der rein simulativ vorgestellte Ansatz keine Validitätsbedingungen für die Gültigkeit der Modellgleichungen. Mit Ausnahme von [31] und den Veröffentlichungen [237, 238], auf denen dieses Kapitel basiert, enthält die Literatur nach dem besten Wissen des Autors aktuell keine vergleichbaren Ansätze zur aktiven Fehlerdiagnose in RBSs. Auch wenn die aktive Fehlerdiagnose in Batteriesystemen ein neues Anwendungsgebiet ist, gibt es Ansätze in anderen Bereichen [91, 198, 220]. Gelso und Blanke wenden ihren Ansatz beispielhaft auf ein Positionierungssteuerungssystem eines Offshore-Schiffs an [91]. Poulsen und Niemann wählen ein synthetisches Beispielsystem und Mesbah, Streif u. a. wenden ihren Ansatz auf ein Drei-Tank-Benchmark-System an [198, 220]. Die drei genannten Ansätze erreichen eine aktive Fehlerdiagnose durch Modifikation des Eingangssignals des Systems. Das Einbringen eines zusätzlichen Eingangssignals ist in Batteriesystemen jedoch nachteilig, da es zusätzliche Verluste beim Betrieb des Energiespeichers verursacht.


Diese Arbeit stellt eine neuartige Methode zur aktiven Hypothesenprüfung vor, die auf früheren Untersuchungen von [34, 203, 205, 206] basiert. Chernoff hat ein Verfahren zum Testen von  $|\mathbb{H}| = 2$  verschiedenen Hypothesen  $\mathcal{H}_1, \mathcal{H}_2 \in \mathbb{H}$  eingeführt, die für alle Aktionen eindeutig unterscheidbar sind und zeigt dessen asymptotische Optimalität ( $L \rightarrow \infty$ ) für die Kosten  $L$  einer falschen Deklaration [34]. Nitinawarat, Atia und Veeravalli sowie Naghshvar und Javidi verallgemeinern den Ansatz von Chernoff, mildern die Notwendigkeit der Unterscheidbarkeit und erlauben den Test mehrerer Hypothesen ( $|\mathbb{H}| > 2$ ) [203, 205, 206]. Cohen und Zhao verwendeten aktives Hypothesentesten für die Anomalieerkennung. Ziel ist es, die Ursache eines Fehlers zu finden, indem der Test sukzessive einen Messunterraum auswählt, um zu prüfen, ob die Messungen auf eine Anomalie im gemessenen Teilsystem hinweisen oder nicht [40]. Durch Wiederholung dieser Prozedur sind Cohen und Zhao in der Lage, Anomalien zu isolieren. Die Ansätze [34, 40, 203, 205, 206] haben gemeinsam, dass die Entscheidung auf dem Vergleich der Wahrscheinlichkeitsdichtefunktion der Residuen nach der Aktion, genannt *Kernels*, basiert, wobei jede Hypothese als wahr angenommen wird. Diese Kernels sind jedoch im Allgemeinen unbekannt und schwer abzuschätzen, da sie stark von der Fehleramplitude abhängen. Schnell variierende Fehleramplituden und die Ungewissheit über den wahren Fehler im System erschweren die Schätzung der Kernels zusätzlich. Diese Herausforderung nimmt die vorliegende Arbeit zum Anlass, eine aktive Hypothesenprüfungsstrategie zu entwickeln, die auf [203] basiert aber ohne eine Kenntnis der Fehleramplitude auskommt.

## 5.2 Modell des rekonfigurierbaren Batteriemoduls

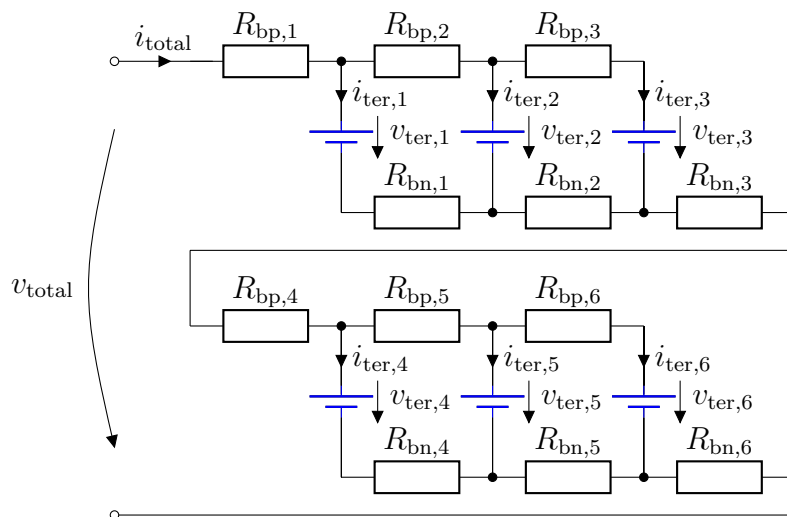
Zur Beschreibung des RBSs erweitert dieser Abschnitt das gekoppelte elektro-thermische Modell aus Kapitel 3 am Beispiel eines Batteriemoduls. Abschnitt 5.2.1 stellt das elektrische und Abschnitt 5.2.2 das thermische Modell vor. Abschließend fasst Abschnitt 5.2.3 die geltenden Systemgleichungen zusammen, auf deren Grundlage die strukturelle Analyse des Batteriemoduls erfolgt.

### 5.2.1 Elektrisches Modell

Die Basis der nachfolgenden Untersuchungen bildet das Modell einer rekonfigurierbaren Batteriezelle (siehe Abbildung 5.1, blau) mit zwei Schaltern [129]. Sechs rekonfigurierbare Zellen bilden das in Abbildung 5.2 gezeigte Modul in einer 2s3p-Konfiguration. Die parallel geschalteten Zellen  $i \in \{1, 2, 3\}$  werden als erste Zeile, die Zellen  $i \in \{4, 5, 6\}$  als zweite Zeile bezeichnet. Die Dynamik des Zellmodells mit dem Eingangsstrom  $i_{\text{cell}}$  und der Ausgangsspannung  $v_{\text{cell}}$



**Abbildung 5.1:** RBS-Zelle (blau): 1-RC-Thevenin-Modell einer Lithium-Ionen-Zelle mit einem Aktiv-Schalter (AS) und einem Bypass-Schalter (BS).  $R_{\text{con}}$  ist der Kontaktwiderstand zwischen dem Zellenterminal und der Stromschiene.




**Abbildung 5.2:** Elektrische Verbindung von sechs RBS-Zellen (blau, siehe Abbildung 5.1) unter Berücksichtigung der Stromschiene Widerstände  $R_{\text{bp},i}$ ,  $R_{\text{bn},i}$ . Die erste Reihe enthält die Zellen 1, 2 und 3; die zweite Reihe enthält die Zellen 4, 5 und 6 (2s3p-Konfiguration).

ist durch

$$\begin{bmatrix} \dot{\text{SOC}} \\ \dot{v}_p \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ 0 & -\tau_p^{-1} \end{bmatrix} \cdot \begin{bmatrix} \text{SOC} \\ v_p \end{bmatrix} + \begin{bmatrix} Q^{-1} \\ C_p^{-1} \end{bmatrix} \cdot i_{\text{cell}} \quad (5.281)$$

$$[v_{\text{cell}}] = [E_m/\text{SOC} \quad 1] \cdot \begin{bmatrix} \text{SOC} \\ v_p \end{bmatrix} + [R_o] \cdot i_{\text{cell}} \quad (5.282)$$

gegeben, wobei  $i_{\text{cell}} > 0$  einem Ladestrom entspricht [23, 245, 277]. Dabei ist  $E_m$  die Leerlaufspannung (elektromotorische Kraft), SOC der Ladezustand und  $v_p$  die Polarisationsspannung



**Abbildung 5.3:** Thermisches Cauer-Modell mit zwei Zuständen für die Zellkerntemperatur  $T_c$  und Oberflächentemperatur  $T_s$ . Den Eingang bilden die Wärmegenerierung  $P_{\text{cell}}$  und die Umgebungstemperatur  $T_{\text{amb}}$ .

des RC-Glieds.  $Q$  bezeichnet die Kapazität der Zelle und  $\tau_p = R_p C_p$  die Zeitkonstante des RC-Glieds. Durch Parametrierung des Modells entsprechend dem verwendeten Zelltyp lässt sich eine Vielzahl von Zelltypen mit unterschiedlichen Kapazitäten modellieren. An der Verbindung der Zelle mit der Stromschiene tritt ein Kontaktwiderstand  $R_{\text{con}}$  auf. Die Widerstände  $R_{\text{bn},i}$  und  $R_{\text{bp},i}$  modellieren die Stromschiene.

Die galvanische Zelle kann mit dem Bypass-Schalter (BS) überbrückt und mit dem Aktiv-Schalter (AS) an den Strompfad angeschlossen werden. Ein unendlicher *Off*-Widerstand  $R_{\text{act}} = R_{\text{act,off}}$ ,  $R_{\text{byp}} = R_{\text{byp,off}}$  und ein kleiner *On*-Widerstand  $R_{\text{act}} = R_{\text{act,on}}$ ,  $R_{\text{byp}} = R_{\text{byp,on}}$  modellieren die Schalter als ideale Leistungsschalter. Geöffnete Schalter (*Off*-Zustand) entsprechen im fehlerfreien Fall einem idealen Leerlauf. Ein Fehler kann die *Off*-Widerstände jedoch verringern. Jeweils nur einer der beiden Schalter darf geschlossen sein (*On*-Zustand), was zu den folgenden drei erlaubten Schalterzuständen führt: *Active*-Zustand, wenn der AS geschlossen ist; *Bypass*-Zustand, wenn der BS geschlossen ist; *Idle*-Zustand, wenn keiner der beiden Schalter geschlossen ist. Innerhalb des Moduls ergeben sich zwei weitere Beschränkungen: Wenn der BS einer Zelle geschlossen ist, müssen alle ASs der dazu parallelen Zellen offen sein, um keinen niederohmigen Kurzschluss zu verursachen. Die zweite Beschränkung ist, dass immer mindestens ein Schalter (AS oder BS) innerhalb einer Parallelgruppe von Zellen geschlossen sein muss, da sonst ein Leerlauf im Leistungspfad vorliegt. Außerdem muss mindestens eine Zelle innerhalb des gesamten Moduls aktiv sein, um einem Kurzschluss der Quelle oder Last vorzubeugen.

### 5.2.2 Thermisches Modell

Um der thermischen Abhängigkeit der Zellparameter gerecht zu werden, erfolgt neben der elektrischen auch eine thermische Modellierung der Zellen. Abbildung 5.3 zeigt die ECM-Darstellung des thermischen Cauer-Modells zweiter Ordnung [79, 167]. Der Wärmeeintrag von Nachbarzellen oder der Elektronik (siehe Abschnitt 3.2.2) wird an dieser Stelle vernachlässigt.  $T_c$ ,  $T_s$  und  $T_{\text{amb}}$  sind die Zellkerntemperatur, die Zelloberflächentemperatur beziehungsweise die Umgebungstemperatur.  $C_c$  und  $C_s$  stellen die Wärmekapazitäten des Kerns und der Oberfläche dar. Der Wärmeleitwiderstand des Kerns und der Konvektionswiderstand der Oberfläche sind durch  $R_c$  und  $R_s$  gegeben. Basierend auf dem elektrischen Modell ist die



Joulesche Erwärmung und die Verlustleistung durch die Überspannung gegeben als

$$P_{\text{cell}} = R_o i_{\text{cell}}^2 + \frac{v_p^2}{R_p}. \quad (5.283)$$

Die maßgebende Differentialgleichung für die beiden Zustände  $T_c$  und  $T_s$  lautet

$$\begin{bmatrix} \dot{T}_c \\ \dot{T}_s \end{bmatrix} = \begin{bmatrix} -\tau_c^{-1} & \tau_c^{-1} \\ \tau_{cs}^{-1} & -\tau_s^{-1} - \tau_{cs}^{-1} \end{bmatrix} \begin{bmatrix} T_c \\ T_s \end{bmatrix} + \begin{bmatrix} C_c^{-1} & 0 \\ 0 & \tau_s^{-1} \end{bmatrix} \begin{bmatrix} P_{\text{cell}} \\ T_{\text{amb}} \end{bmatrix} \quad (5.284)$$

mit den thermischen Zeitkonstanten  $\tau_c = R_c C_c$ ,  $\tau_s = R_s C_s$  und  $\tau_{cs} = R_c C_s$ .

### 5.2.3 Systemgleichungen

Aus den elektrischen und thermischen Gleichungen der beiden Abschnitte 5.2.1 und 5.2.2 ergeben sich die Systemgleichungen des gesamten Moduls. Tabelle 5.1 fasst die Modellgleichungen für die  $n_{\text{cell}} = 6$  RBS-Zellen zusammen. Zudem ist rechts eine Validitätsbedingung gegeben, für die die jeweilige Gleichung gilt. Eine '1' bedeutet, dass die Gleichung nur gültig ist, wenn der  $i$ -te Schalter geschlossen ist, eine Gleichung mit Zustand '0' gilt nur, wenn der  $i$ -te Schalter offen ist. Ein Sternchen '\*' bedeutet, dass die Gleichung unabhängig vom Zustand des  $i$ -ten Schalters im System ist. Daher lässt sich eine Gleichung mit einer '1' an der  $i$ -ten Stelle in ihrer Validitätsbedingung nicht mit einer Gleichung mit einer '0' an der  $i$ -ten Stelle in ihrer Validitätsbedingung kombinieren. Sie kann jedoch mit einer Gleichung kombiniert werden, die an der  $i$ -ten Stelle ein Sternchen hat.

Die Gleichung  $e_{1,i}$  (siehe Tabelle 5.1) entspricht der zweiten Systemgleichung (5.281) bei geschlossenem AS. Der zusätzliche Index  $i$  dient dazu, die Gleichungen für jede der  $i \in [1, 6]$ -Zellen zusammenzufassen. Aufgrund der Annahme idealer Schalter gilt bei offenem AS  $i_{\text{cell}} = 0$ , was zu  $e_{2,i}$  führt. Aus der Ausgangsgleichung (5.282) für jede Zelle folgt  $e_{3,i}$  bei geschlossenem AS und  $e_{4,i}$  bei offenem AS. Die Gleichungen  $e_{5,i}$ ,  $e_{6,i}$  und  $e_{7,i}$  folgen nach der Kirchhoffschen Maschenregel (Kirchhoff's-Voltage-Law, KVL) (siehe Abbildung 5.1). Der Strom  $\hat{i}_{\text{act,off},i}$  ist im fehlerfreien Fall Null und weicht nur im Fehlerfall von Null ab (siehe  $e_{\theta,i}$ ). Im fehlerfreien Fall mit geschlossenem AS gilt nach der Kirchhoffschen Knotenregel (Kirchhoff's-Current-Law, KCL)  $i_{\text{ter},i} = i_{\text{cell},i}$ . Für einen Leckstrom im Fehlerfall wird  $\hat{i}_{\text{byp,off},i}$  eingeführt ( $e_{8,i}$ ). Durch das KCL folgt  $e_{9,i}$ , wenn beide Schalter offen sind und  $e_{10,i}$ , wenn der AS offen ist. Aus der Systemgleichung (5.284) des thermischen Modells folgen  $e_{11,i}$  und  $e_{12,i}$ . Die Variablen  $\overline{R_{c,i}}$ ,  $\overline{C_{c,i}}$ ,  $\overline{R_{s,i}}$ ,  $\overline{C_{s,i}}$  und  $\overline{T_{\text{amb}}}$  entsprechen bekannten Größen aus dem Modell – aufgrund einer Messung oder vorangegangenen Systemidentifikation – und sind durch einen Überstrich gekennzeichnet. Die Wärmegenerierung jeder Zelle ist abhängig vom Schaltzustand: Ist der AS geschlossen, gilt  $e_{13,i}$ ; ist der AS offen, gilt  $e_{14,i}$ . Nach dem KVL folgen  $e_{15,i}$  und  $e_{16}$  (siehe Abbildung 5.2).  $n_{\text{cell}} = 6$  ist die Gesamtzahl der Zellen,  $n_{\text{par}} = 3$

**Tabelle 5.1:** Modellgleichungen für das RBS-Modul aus Abbildung 5.2.

Gleichung	AS <sub><i>i</i></sub>	BS <sub><i>i</i></sub>
$e_{1,i} : 0 = i_{\text{cell},i} C_{\text{p},i}^{-1} - \dot{v}_{\text{p},i} - v_{\text{p},i} R_{\text{p},i}^{-1} C_{\text{p},i}^{-1}$	1	0
$e_{2,i} : 0 = -\dot{v}_{\text{p},i} - v_{\text{p},i} R_{\text{p},i}^{-1} C_{\text{p},i}^{-1}$	0	*
$e_{3,i} : 0 = E_{\text{m},i} + v_{\text{p},i} - v_{\text{cell},i} + R_{\text{o},i} i_{\text{cell},i}$	1	0
$e_{4,i} : 0 = E_{\text{m},i} + v_{\text{p},i} - v_{\text{cell},i}$	0	*
$e_{5,i} : 0 = v_{\text{byp},i} - v_{\text{ter},i} + R_{\text{con},i} i_{\text{ter},i}$	*	*
$e_{6,i} : 0 = v_{\text{byp},i} - R_{\text{byp,on},i} (i_{\text{ter},i} - \hat{i}_{\text{act,off},i})$	0	1
$e_{7,i} : 0 = v_{\text{cell},i} - v_{\text{byp},i} + R_{\text{act,on},i} i_{\text{cell},i}$	1	0
$e_{8,i} : 0 = i_{\text{ter},i} - i_{\text{cell},i} - \hat{i}_{\text{byp,off},i}$	1	0
$e_{9,i} : 0 = i_{\text{ter},i} - \hat{i}_{\text{byp,off},i} - \hat{i}_{\text{act,off},i}$	0	0
$e_{10,i} : 0 = i_{\text{cell},i} - \hat{i}_{\text{act,off},i}$	0	*
$e_{11,i} : 0 = \dot{T}_{\text{c},i} - P_{\text{cell},i} \overline{C_{\text{c},i}}^{-1} + (T_{\text{c},i} - T_{\text{s},i}) \overline{C_{\text{c},i}}^{-1} \overline{R_{\text{c},i}}^{-1}$	*	*
$e_{12,i} : 0 = \dot{T}_{\text{s},i} - (T_{\text{c},i} - T_{\text{s},i}) \overline{C_{\text{s},i}}^{-1} \overline{R_{\text{c},i}}^{-1} - (\overline{T_{\text{amb}}} - T_{\text{s},i}) \overline{C_{\text{s},i}}^{-1} \overline{R_{\text{s},i}}^{-1}$	*	*
$e_{13,i} : 0 = P_{\text{cell},i} - R_{\text{o},i} i_{\text{cell},i}^2 - v_{\text{p},i}^2 R_{\text{p},i}^{-1}$	1	0
$e_{14,i} : 0 = P_{\text{cell},i} - v_{\text{p},i}^2 R_{\text{p},i}^{-1}$	0	*
$e_{15,\alpha} : 0 = v_{\text{ter},i} - v_{\text{ter},i+1} + \sum_{j=p_0(i)}^i \left( R_{\text{bn},j} \sum_{k=p_0(i)}^j i_{\text{ter},k} \right) - \sum_{j=p_0(i)}^i R_{\text{bp},j} \left( i_{\text{total}} - \sum_{k=p_0(i)}^j i_{\text{ter},k} \right)$	*	*
$e_{15,\beta} : 0 = i_{\text{total}} - \sum_{j=p_0(i)}^i i_{\text{ter},j}$	*	*
$e_{16} : 0 = v_{\text{total}} - \sum_{i=1}^{n_{\text{cell}}} R_{\text{bn},i} \sum_{k=p_0(i)}^i i_{\text{ter},k} - \sum_{i=1}^{n_{\text{ser}}} v_{\text{ter},s_0(i)} - i_{\text{total}} \sum_{i=1}^{n_{\text{ser}}} R_{\text{bp},s_0(i)}$	*	*
$e_{\theta,i} : 0 = \theta - \bar{\theta} - f_{\theta}$	*	*

mit  $\theta \in \{ i_{\text{cell},i}, i_{\text{total}}, v_{\text{cell},i}, v_{\text{total}}, T_{\text{s},i}, E_{\text{m},i}, R_{\text{o},i}, C_{\text{p},i}, R_{\text{p},i}, R_{\text{con},i}, R_{\text{bn},i}, R_{\text{bp},i}, R_{\text{byp,on},i}, R_{\text{act,on},i}, \hat{i}_{\text{act,off},i}, \hat{i}_{\text{byp,off},i} \}$

die Anzahl der Zellen in Parallelschaltung und  $n_{\text{ser}} = 2$  die Anzahl der Zellen in Serie. Je nach Position der Spannungsmasche gilt entweder  $e_{15,\alpha}$  ( $\alpha \in \{i \mid \text{mod}(i, n_{\text{par}}) \neq 0\}$ ) oder  $e_{15,\beta}$  ( $\beta \in \{i \mid \text{mod}(i, n_{\text{par}}) = 0\}$ ) mit  $p_0(i) = \lfloor ((i-1)/n_{\text{par}}) \rfloor n_{\text{par}}$  und  $s_0(i) = (i-1) \cdot n_{\text{par}} + 1$ . Gleichung  $e_{\theta,i}$  fasst alle weiteren Fehlergleichungen nach dem Prinzip  $\theta = \bar{\theta} + f_{\theta}$  (siehe Abschnitt 5.3.1) zusammen.  $\bar{\theta}$  bezeichnet die fehlerfreie Variable  $\theta$  und  $f_{\theta}$  bezeichnet die Fehleramplitude. Für das vorliegende System, bestehend aus einem RBS-Modul mit sechs Zellen, ergeben sich somit 177 Gleichungen.

## 5.3 Strukturelle Analyse und Berechnung minimaler strukturell überbestimmter Teilsysteme

Basierend auf den Systemgleichungen des vorangegangenen Abschnitts 5.2 erfolgt eine strukturelle Analyse des Batteriemoduls. Dazu untersucht Abschnitt 5.3.1 strukturell die Isolierbarkeit im System und findet eine minimale Sensormenge, die eine maximale Isolierbarkeit verspricht. Da es sich bei RBS-Batteriemodulen um Systeme mit einer Vielzahl an Gleichungen mit einer hohen Redundanz handelt, entwickelt diese Arbeit einen neuartigen Algorithmus, der minimal strukturell überbestimmte Teilsysteme in solchen Systemen auf eine effiziente Weise findet. Nach einer Komplexitätsabschätzung in Abschnitt 5.3.2 führt Abschnitt 5.3.3 den Algorithmus anhand eines Beispiels ein, bevor eine formale Beschreibung und eine Heuristik für eine weitere Verkürzung der Berechnungszeit folgen.

### 5.3.1 Isolierbarkeitsanalyse und minimale Sensormenge eines rekonfigurierbaren Batteriesystems

Um eine vollständige strukturelle Fehleranalyse durchführen zu können, wird angenommen, dass jeder Sensor, Batterieparameter oder Zellkomponente und jeder Aktor fehlerhaft werden kann. Fehler werden als

$$\theta = \bar{\theta} + f_{\theta} \quad (5.285)$$

modelliert, wobei  $\bar{\theta}$  der fehlerfreie Parameter- oder Sensorwert und  $f_{\theta}$  die jeweilige Fehleramplitude ist. Die Menge aller potentiell fehlerhaften Größen setzt sich aus  $\theta = \theta_{\text{Sensor}} \cup \theta_{\text{Parameter}} \cup \theta_{\text{Aktor}}$  mit den Sensoren

$$\theta_{\text{Sensor}} \in \{i_{\text{cell},i}, i_{\text{total}}, v_{\text{cell},i}, v_{\text{total}}, T_{s,i} \mid i \in [1, 6]\}, \quad (5.286)$$

den Zell- oder Systemparametern

$$\theta_{\text{Parameter}} \in \{E_{m,i}, R_{o,i}, R_{\text{con},i}, R_{\text{bn},i}, R_{\text{bp},i} \mid i \in [1, 6]\} \quad (5.287)$$




Abbildung 5.4: Strukturelle Isolierbarkeitsanalyse eines 2s3p-Batteriemoduls.

und den Aktoren

$$\theta_{\text{Aktor}} \in \{R_{act,i}, R_{byp,i} \mid i \in [1, 6]\} \tag{5.288}$$

zusammen. Da für die strukturelle Analyse keine Annahmen bezüglich der Fehleramplitude getroffen werden, sind sowohl Verstärkungs- als auch Offset-Sensorfehler berücksichtigt [153]. Fehler in den Zellen- oder Systemparametern sind anomale Änderungen der entsprechenden Parameter. Analog dazu enthalten Aktorfehler Fehlerzustände, die beispielsweise einer Blockade im geschlossenen (*Stuck-Closed*) oder offenem Zustand (*Stuck-Open*) entsprechen. Aus der Menge aller Fehler  $\theta$  ergeben sich die Achsen der strukturellen Isolierbarkeitsmatrix in Abbildung 5.4. Ordinate und Abszisse sind identisch und enthalten alle möglichen Fehler

$f_{\theta}$ . Zur besseren Lesbarkeit verteilt sich die Beschriftung jeweils auf zwei Achsen. Wie in [135, 174] nimmt die Isolierbarkeitsanalyse an, dass jeweils nur ein einziger Fehler gleichzeitig auftritt (*single-fault*-Annahme) und dass es außer den betrachteten Fehlern keine weiteren gibt (*Closed-World*-Annahme) [82].

Die strukturelle Analyse untersucht zunächst die Isolierbarkeit von Fehlern ohne Berücksichtigung des thermischen Modells. Abbildung 5.4, Fall 1 zeigt die maximale strukturelle Isolierbarkeit von sechs RBS-Zellen. Ein gefülltes Quadrat entspricht einer 1 in der zugehörigen Isolierbarkeitsmatrix und zeigt an, dass ein Fehler auf der Ordinate nicht von einem Fehler auf der Abszisse isolierbar ist. Eine Einheitsmatrix würde eine perfekte strukturelle Isolierbarkeit versprechen. Ohne das thermische Modell ist bereits eine Fehlerisolierung zwischen den Zellen und den Schaltern möglich. Die Kontaktwiderstände sind von einigen Stromschienenwiderständen strukturell jedoch nicht isolierbar. Durch die Einbeziehung des thermischen Modells in die Analyse verbessert sich die strukturelle Isolierbarkeit, wie in Abbildung 5.4, Fall 2 gezeigt. Es ist zu beobachten, dass durch das thermische Modell sogar Parameterfehler innerhalb der Zelle strukturell isolierbar sind. Das Ergebnis der Strukturanalyse sollte jedoch immer als Näherung für die Fehlerisolation in praktischen Anwendungen betrachtet werden. Die strukturelle Analyse setzt, basierend auf den vorhandenen Systemgleichungen, perfekte Systemkenntnis voraus und zeigt somit das maximale Potential für die Fehlerisolation auf. In der Regel verringern sich die Möglichkeiten der Fehlerisolierung, beispielsweise durch Modellunsicherheiten und Sensorrauschen. Zudem sind die elektrischen und thermischen ECMs aus den Abschnitten 5.2.1 und 5.2.2 vereinfachte Darstellungen der Realität. Insbesondere Residuen, die basierend auf dem Temperaturmodell generiert werden, reagieren aufgrund größerer Zeitkonstanten langsam auf Fehler in Parametern oder Sensoren.

Frisk und Krysanter haben in ihrer Arbeit eine graphenbasierte Methode zur Berechnung der minimalen Sensormenge mit maximaler struktureller Isolierbarkeit vorgestellt [82]. Die minimale Sensormenge ist definiert als diejenige Multimenge messbarer Variablen, die in einer maximalen Fehlerisolierbarkeit resultiert, während jede andere geeignete Untermenge die Isolierbarkeit einschränkt. Basierend auf dem Modell des RBS-Moduls werden  $i_{ter,i}$ ,  $i_{cell,i}$ ,  $v_{byp,i}$ ,  $v_{cell,i}$  und  $T_{s,i}$ ,  $i \in [1, 6]$  als mögliche messbare Variablen durch einen Sensor definiert (siehe Abbildungen 5.1, 5.3). Im Fall 1 enthält die resultierende kleinste minimale Sensormenge die Spannung  $v_{cell,i}$  für jede Zelle, die Gesamtspannung  $v_{total}$ , die zweimal mit zwei unabhängigen Sensoren gemessen wird, und eine Messung des Gesamtstroms  $i_{total}$ . Unter Einbeziehung des thermischen Modells reicht es aus, die Temperatur  $T_{s,i}$  jeder Zelle, die redundant gemessene Gesamtspannung  $v_{total}$  und den Gesamtstrom  $i_{total}$  zu messen, um die maximale strukturelle Isolierbarkeit zu erhalten, wie in Abbildung 5.4, Fall 2 gezeigt. Die Prognose der Isolierbarkeit mit der minimalen Sensormenge sollte jedoch immer im Hinblick auf die nicht-perfekte Systemkenntnis evaluiert werden. So ist im Fall 2 beispielsweise zu erwarten, dass der Einfluss von Sensorrauschen und Modellunsicherheiten schnell überwiegt, wenn das thermische Modell die Strommessungen  $i_{ter,i}$  zur Fehlerdiagnose rekonstruiert.

Basierend auf der strukturellen Analyse resultiert die folgende Sensormenge für die nachfolgenden Untersuchungen: Die Zellspannungen  $v_{\text{cell},i}$ , die Zellströme  $i_{\text{cell},i}$  und die Oberflächentemperaturen  $T_{s,i}$  für jede RBS-Zelle  $i \in [1, 6]$  sowie die Gesamtspannung  $v_{\text{total}}$  und der Gesamtstrom  $i_{\text{total}}$ . Da die Gesamtspannung nur einmal gemessen wird, führt diese Sensortopologie zu einem leichten Verlust der strukturellen Isolierbarkeit, wie in Abbildung 5.4 blau dargestellt. Abschnitt 5.6.3 zeigt jedoch, dass diese teilweise wiederhergestellt werden kann, da zusätzliches Systemwissen vorhanden ist. In diesem Fall ist eine Information über das Vorzeichen der Fehler bekannt.

### 5.3.2 Algorithmus zur Berechnung minimal strukturell überbestimmter Teilsysteme

Anhand von Residuen lassen sich Fehler in Systemen detektieren. Für die Konstruktion von Residuen werden in der Literatur häufig überbestimmte Teilsysteme verwendet [6]. Krysander, Aslund und Nyberg zeigen, dass strukturell überbestimmte Teilsysteme mit einer Redundanz  $\varphi_s = 1$ , also die aus Abschnitt 2.4.6 bekannten, minimal strukturell überbestimmten MSO-Teilsysteme<sup>1</sup>, am besten für diese Aufgabe geeignet sind [152]. Die Berechnung von MSO-Teilmenge erlaubt nicht nur die Verwendung bereits entwickelter, residuenbasierter Verfahren wie Beobachter [53, 69, 306], Kalman-Filter [173, 324] oder Paritätsgleichungen [35, 70, 214], sondern reduziert auch die Komplexität der Fehlerdiagnose [123].

Es gibt eine Reihe von verschiedenen Algorithmen zur Berechnung von MSO-Teilsystemen [92, 152, 222, 280]. Ein Vergleich zwischen diesen verschiedenen Ansätzen findet sich in [6]. Jeder dieser Ansätze berechnet die Gesamtheit aller MSO-Teilsysteme. Wie Krysander, Aslund und Nyberg zeigen, steigt die maximale Anzahl der MSO-Teilsysteme kombinatorisch mit der Anzahl der Gleichungen  $n_{\mathbb{E}}$  und der strukturellen Redundanz  $\varphi_s$  [152]:

$$\sum_{k=n_{\mathbb{E}}-\varphi_s+1}^{n_{\mathbb{E}}} \binom{n_{\mathbb{E}}}{k}. \quad (5.289)$$

Für große Systeme mit einem hohen Grad an Redundanz, wie Batteriesysteme, führt dies zu einer rechnerisch erschöpfenden Anzahl von MSO-Teilsystemen. Das Ziel dieser Arbeit ist deshalb, die besten Kandidaten von MSO-Subsystemen für die Residuengenerierung in Bezug auf die minimalen Modellunsicherheiten zu finden. Jede Gleichung in einem Modell ist von Modellunsicherheiten betroffen, die aus Unsicherheiten in der Modellstruktur und in den Parametern resultieren. Unter der Annahme, dass jede Gleichung im System von der gleichen Menge an Modellunsicherheit betroffen ist, ist das optimale MSO-Subsystem zur Konstruktion eines Residuums mit der geringsten Modellunsicherheit dasjenige, das die kleinste Anzahl an Gleichungen besitzt. Diese Annahme trifft nicht im Allgemeinen zu. Es ist

<sup>1</sup>System, Menge und Set werden im Zusammenhang mit der strukturellen Analyse synonym verwendet.

jedoch intuitiv anzunehmen, dass die besten MSO-Subsysteme für die Residuengenerierung zu den Kandidaten mit den wenigsten Gleichungen gehören. Sofern es für ein System möglich ist, die Modellunsicherheit jeder Gleichung zu beziffern, kann alternativ auch diese für die Bewertung der besten MSO-Subsysteme herangezogen werden. Da sich die Modellunsicherheit jeder Gleichung im vorliegenden System nicht ohne weiteres beziffern lässt, wird nachfolgend ein Algorithmus vorgestellt, der garantiert, die MSO-Subsysteme mit der geringsten Anzahl an Gleichungen auszugeben. Außerdem bietet der Algorithmus im Unterschied zu [92, 152, 222] die Möglichkeit, Validitätsbedingungen für jede Gleichung aufzunehmen. Die Berücksichtigung von Validitätsbedingungen zu jeder Gleichung ist durch den binären Ausgang der Schaltzustände für die Systemgleichungen motiviert. Abhängig von ihrem Zustand vereinfachen sich einige Gleichungen. Ein AS im *Off*-Zustand resultiert beispielsweise in  $i_{\text{cell},i} \approx 0$  – vorausgesetzt, der zugehörige Leistungsschalter ist nicht defekt. In ähnlicher Weise führt ein fehlerfreier BS im *Off*-Zustand zu  $i_{\text{byp},i} \approx 0$ .

### Formale Beschreibung des Algorithmus

Ziel des nachfolgend vorgestellten Greedy-Algorithmus ist es, die kleinste MSO-Teilmenge für jeden möglichen Fehler im System zu berechnen. Im Unterschied zu [280] basiert der Ansatz auf einer Breitensuche anstelle einer Tiefensuche. Ausgehend von einer anfänglichen Fehlervariablen  $f_0$  erkundet der Algorithmus die Systemgleichungen und ihre Variablen. In jedem Schritt analysiert er eine besuchte Variable und ihr Vorkommen in den Systemgleichungen. Alle nicht bearbeiteten Variablen in jeder Gleichung speichert eine Tabelle als besuchte Variablen. Auf Basis einer Best-Case-Schätzung für die minimale Kardinalität einer MSO-Menge, die sowohl die jeweilige Variable als auch den Anfangsfehler  $f_0$  enthält, bewertet der Algorithmus dann die aktuell besuchten Variablen. Die nächste zu bearbeitende Variable ist stets die besuchte Variable mit der niedrigsten geschätzten Kardinalität der MSO-Menge. Der Algorithmus terminiert, wenn ein MSO-Subsystem gefunden wird, das den Ausgangsfehler  $f_0$  enthält. Dieses Vorgehen ist vergleichbar mit dem Dijkstra-Algorithmus [43, Kapitel 6]. Zusätzlich berücksichtigen Fallunterscheidungen die vorhandenen Validitätsbedingungen. Jede Gleichung bringt unterschiedliche Bedingungen (Bed.) mit. Bei der Bearbeitung einer Variablen  $x_i$  analysiert der Algorithmus jede Gleichung  $e_j$  separat, die  $x_i$  enthält, sodass sich die Bedingungen für  $e_j$  berücksichtigen lassen. Die Variable  $x_i$  ist nur unter bestimmten Bedingungen vom Fehler  $f_0$  aus erreichbar. Der Algorithmus berechnet also, ob die Bedingung von  $e_j$  mit der Bedingung zum Erreichen der Variablen  $x_i$  kombinierbar ist. Wenn sie nicht kombinierbar ist, entfällt dieser Pfad. Ist er kombinierbar, so speichert der Algorithmus alle nicht bearbeiteten und nicht besuchten Variablen in  $e_j$  als neu besuchte Variablen.

Algorithmus 5.1 zeigt die formale Beschreibung des vorgeschlagenen Ansatzes. Er berechnet das kleinste MSO-Subsystem für einen gegebenen Fehler *fault* als Eingang. Zeilen 1-3 des Algorithmus 5.1 initialisieren alle Variablen. Die Standardbedingung ist  $[\ast, \ast, \ast, \dots, \ast]$  (*Don't-*

**Algorithmus 5.1** Finden des kleinsten MSO-Subsets (Pseudocode)**Input:** *fault*


---

```

1: visitedVars  $\leftarrow$  [fault]
2:  $\mathbb{B} \leftarrow \{[*], [*], [*], \dots, [*]\}$  ▷ Menge aller Bedingungen
3: MSOfound  $\leftarrow$  false
4: while  $\neg$ MSOfound  $\vee$  visitedVars  $\neq$   $\emptyset$  do
5:   V  $\leftarrow$  visitedVars.firstElement
6:   visitedVars.delete(V)
7:   Equations  $\leftarrow$  V.Equations()
8:   EvalVar ▷ Algorithmus 5.2
9:   for all  $\{Bi \in \mathbb{B} : Bi.newEq \wedge Bi.msoLn < \min(\mathbb{B}.msoLn)\}$  do
10:     EvalRequirement ▷ Algorithmus 5.3
11:     Bi.newEq  $\leftarrow$  false
12:     MoreGeneralB  $\leftarrow$  findSubset(Bi) ▷ Bemerkung 5.1
13:     MoreGeneralB.msoLn  $\leftarrow$  Bi.msoLn
14:   end for
15:   visitedVars  $\leftarrow$  sort(visitedVars, 'ascend by msoLn')
16:   if MSOtemp with minimal length has no auxiliary equations then
17:     MSOfound  $\leftarrow$  true
18:   end if
19: end while

```

---

*Care*). Innerhalb der *while*-Schleife (Algorithmus 5.1, Zeilen 4-19) wird das erste Element in der Liste der bis dahin besuchten Variablen *visitedVars* entnommen und durch den Algorithmus **EvalVar** (Algorithmus 5.2) bearbeitet. Algorithmus 5.1 berechnet zunächst in den Zeilen 9-14 eine untere Schranke für die kleinsten MSO-Teilsysteme für alle Bedingungen beziehungsweise passt diese an. Der Algorithmus bricht ab, wenn eine MSO-Menge ohne Hilfsgleichung gefunden wurde und jede andere aktuelle MSO-Set-Schätzung (mit oder ohne Hilfsgleichung) eine größere Kardinalität besitzt. Algorithmus 5.2 und Algorithmus 5.3 sind als Skripte zu betrachten und werden aus Gründen der Übersichtlichkeit getrennt dargestellt.

Algorithmus 5.2 besucht jede erfüllbare Gleichung, in der die aktuelle Variable vorkommt. Eine Gleichung ist erfüllbar, wenn die Gleichungsbedingung zu der aktuellen Bedingung passt, die bearbeitete Variable vom Ausgangsfehler aus erreichbar ist und vorher nicht besucht wurde. Die Funktion **combine** kann zusätzliche Bedingungen generieren, wenn diese nicht bereits vorhanden sind. Der Algorithmus kopiert dabei die Gleichungen und Variablen für jede neu generierte Bedingung aus der jeweiligen ursprünglichen Bedingung. Falls die Bedingung der Gleichung nicht zu der Bedingung der aktuell bearbeiteten Variable passt, wird *Bcom* auf *null* gesetzt und die Schleife beendet. Für jede Bedingung werden die besuchten Gleichungen und besuchten Variablen gespeichert.



**Algorithmus 5.2** EvalVar (Pseudocode)

---

```

1: for all  $Eq \in Equations$  do
2:    $Bcom \leftarrow combine(Eq.Requirement, V.Requirements)$ 
3:   if  $isnull(Bcom)$  then
4:     continue
5:   end if
6:    $\mathbb{B} \leftarrow \mathbb{B} \cup \{Bcom\}$ 
7:    $V.Requirements \leftarrow V.Requirements \cup \{Bcom\}$ 
8:    $S.newEq \leftarrow true$ 
9:   for all  $\tilde{B} \in Bcom$  do
10:    if  $Eq \notin \tilde{B}.Equations$  then
11:       $\tilde{B}.Equations \leftarrow \tilde{B}.Equations \cup Eq$ 
12:      for all  $W \in \{Eq.Variables\} \setminus \{\tilde{B}.Variables\}$  do
13:         $visitedVars \leftarrow visitedVars \cup \{W\}$  ▷  $W$ : nicht besuchte Variablen
14:         $\tilde{B}.Variables \leftarrow \tilde{B}.Variables \cup \{W\}$ 
15:      end for
16:    end if
17:  end for
18: end for

```

---

Der Algorithmus 5.3 ist von Gelso, Castillo und Armengol inspiriert [92]. Wie zu Beginn des Abschnitts beschrieben, sollen, anstelle einer vollständigen strukturellen Analyse, nur die kleinsten MSO-Teilmengen gefunden werden. Unter dieser Prämisse ist der Algorithmus effizienter implementiert. Gelso, Castillo und Armengol kombinieren sogenannte Basis-MSO-Mengen, die durch einen Maximum-Matching-Algorithmus erzeugt werden, mit der folgenden Regel [92]: Seien  $a$  und  $b$  irgendeine Kombination von Basis-MSO-Subsystemen oder einzelne Basis-MSO-Sets, dann lässt sich eine neue Kombination  $c$  von MSO-Subsystemen als

$$c = (a \cup b) \setminus ab \quad (5.290)$$

schreiben, wobei  $ab \subseteq a \cap b$ . Es lässt sich also eine untere (und obere) Schranke für die Kardinalität von  $c$  einführen:

$$|c| \geq |(a \cup b) \setminus (a \cap b)| = |a| + |b| - 2|(a \cap b)|. \quad (5.291)$$

Gelso, Castillo und Armengol zeigen, dass sich alle MSO-Subsysteme in einem System auf diese Weise erzeugen lassen [92]. Wenn die mit Gleichung (5.291) berechnete untere Schranke größer ist als die kleinste Basis-MSO-Menge, die den Ausgangsfehler enthält, verwirft der Algorithmus die Kombination. Die Berechnung der unteren Schranke benötigt sehr wenig Rechenleistung im Vergleich zur Berechnung der eigentlichen MSO-Sets. Anhand dieser

unteren Schranke sortiert der Algorithmus die Kombinationen der Basis-MSO-Mengen und arbeitet sie in einer priorisierten Reihenfolge ab, bis die kleinste MSO-Menge gefunden ist. Die formale Beschreibung der Implementierung liefert Algorithmus 5.3. Zur Berechnung aller MSO-Subsysteme der Basis-MSO-Set-Kombination in Zeile 17 lässt sich einer der in [92, 152, 222, 280] vorgestellten Algorithmen verwenden. Der vorliegende Algorithmus verwendet den Ansatz von Krysander, Aslund und Nyberg, da er sehr recheneffizient ist und eine Vorgabe von Gleichungen erlaubt, die in den MSO-Sets enthalten sein müssen [152]. Da die strukturelle Redundanz für die Kombination von Basis-MSO-Sets und die Menge ihrer Gleichungen gering ist, ist der Rechenaufwand in diesem Schritt im Vergleich zum gesamten System überschaubar. Algorithmus 5.3 berechnet in Zeile 18 für alle aktuellen Bedingungen das kleinste MSO-Teilsystem oder eine untere Schranke für die Kardinalität des jeweiligen Teilsystems im aktuellen Schritt. Falls keine MSO-Menge gefunden werden kann, die die *faultEq* enthält, setzt der Algorithmus die Länge auf  $\infty$ .

### Heuristik für eine schnellere Berechnungszeit

Nach mehreren Schritten kann jede Bedingung im Algorithmus zahlreiche Gleichungen haben. Bei großen Systemen gibt es in der Regel viele Basis-MSO-Subsysteme in der Funktion **EvalRequirement** (Algorithmus 5.3). Da diese im nächsten Schritt kombiniert werden, führt dies zu einem kombinatorischen Wachstum. Mit der Annahme, dass die Kombination einer größeren Anzahl an Basis-MSO-Subsystemen zu einem größeren MSO-Subsystem führt, steigt die Größe der MSO-Subsysteme mit zunehmender Anzahl an Basis-MSO-Sets. Gleichung (5.291) liefert eine untere Schranke für die Kombination von zwei verschiedenen MSO-Mengen  $a$  und  $b$ . Für die untere Schranke der Kombination  $d$  von drei Basis-MSO-Subsystemen  $a$ ,  $b$  und  $c$  folgt

$$|d| \geq |a| + |b| + |c| - 3|(a \cap b \cap c)| > |a| + |b| - 2|(a \cap b)|. \quad (5.292)$$

Die Gleichheit von  $|a| + |b| + |c| - 3|(a \cap b \cap c)|$  und  $|a| + |b| - 2|(a \cap b)|$  kann nicht gelten, da hierfür  $c = a \cap b$  zutreffen müsste. Nachdem aber  $a$  und  $b$  zwei verschiedene MSO-Subsysteme sind, kann  $a \cap b$  kein weiteres MSO-Subsystem sein. Daher steigt die untere Schranke mit jeder weiteren Kombination an. Aus dieser Beobachtung ergibt sich die Folgerung, dass mit einer zunehmenden Anzahl an kombinierten Basis-MSO-Subsystemen zu einem weiteren MSO-Subsystem die Wahrscheinlichkeit sinkt, dass das neu generierte System das insgesamt kleinste MSO-Subsystem ist. Eine mögliche Heuristik besteht also darin, nach einer bestimmten Anzahl von Kombinationen zu terminieren. Dies geschieht durch Begrenzung der Anzahl  $n$  der Basis-MSO-Sets in Algorithmus 5.3, Zeile 6. In der nachfolgenden Implementierung des Algorithmus wird  $n$  auf  $n = 5$  gesetzt.

**Algorithmus 5.3** EvalRequirement (Pseudocode)

---

```

1:  $Eqs \leftarrow Bi.Equations() \cup Bi.AuxEquations()$ 
2:  $basicMSOList \leftarrow calcBasicMSO(Eqs)$  ▷ Maximal-Matching-Algorithmus [92]
3:  $MSOList \leftarrow \emptyset$ 
4:  $faultEq \leftarrow fault.Equation()$ 
5:  $mL \leftarrow$  minimal length of basic MSO set with  $faultEq$ 
6: for all combinations  $\{m_1, \dots, m_n\}$  of  $m_i$  in  $basicMSOList$  do ▷  $m_i$ : Basis-MSO-Set
7:    $lB \leftarrow \begin{cases} |m_1| & n = 1 \\ \sum_{i=1}^n |m_i| - n \left| \bigcap_{i=1}^n m_i \right| & n \neq 1 \end{cases}$  ▷ Berechnung der unteren Schranke nach (5.291)
8:   if  $lB < mL \wedge faultEq \in \bigcup_{i=1}^n m_i$  then
9:      $MSOList.append\left(\bigcup_{i=1}^n m_i\right)$ 
10:     $lowerBound.append(lB)$ 
11:   end if
12: end for
13:  $[lowerBound, sortIdx] \leftarrow sort(lowerBound, 'ascend')$ 
14:  $MSOList \leftarrow MSOList(sortIdx)$ 
15:  $minMSOfound \leftarrow false$ 
16: while  $\neg minMSOfound \vee all(lowerBound == \infty)$  do
17:    $allMSO \leftarrow calcAllMSO(MSOList.firstElement, 'contains faultEq')$ 
18:    $[lB, idxMin] \leftarrow min(ElementLength(allMSO))$ 
19:    $MSOList.firstElement \leftarrow allMSO(idxMin)$ 
20:   if  $lB == lowerBound(1)$  then ▷ Garantiert kleinstes MSO-Set für die Bedingung  $Bi$ 
21:      $minMSOfound \leftarrow true$ 
22:      $Bi.MSO_{temp} \leftarrow allMSO(idxMin)$ 
23:      $Bi.msoLn \leftarrow lB$ 
24:      $Bi.noEq_{aux} \leftarrow any(Bi.AuxEquations(\notin Bi.MSO))$ 
25:   else
26:      $lowerBound.firstElement \leftarrow lB$ 
27:   end if
28:    $[lowerBound, sortIdx] \leftarrow sort(lowerBound, 'ascend')$ 
29:    $MSOList \leftarrow MSOList(sortIdx)$ 
30: end while

```

---

**Tabelle 5.2:** Gespeicherte Daten des Algorithmus nach Schritt 1.

Bed.	Gleichungen	Var <sub>visited</sub>	Eq <sub>aux</sub>	MSO <sub>temp</sub>
[*,*]	$e_7$	$x_3$	$e_{\text{aux},x_3}$	$\{e_7, e_{\text{aux},x_3}\}$

### 5.3.3 Demonstration an einem Beispielsystem

Das nachfolgende Beispielsystem (Beispiel 5.1) demonstriert den Ablauf des Algorithmus.

#### Beispiel 5.1.

	Bed.
$e_1 : 0 = x_1^2 + 2x_2 + \bar{a}$	[*,*]
$e_2 : 0 = x_2 + 4x_3 - \bar{b}$	[1,*]
$e_3 : 0 = x_1 + x_3 - \bar{b}$	[0,*]
$e_4 : 0 = x_1 + x_2^3 + \bar{a}/2$	[*,1]
$e_5 : 0 = x_1 + x_2^3 + 2\bar{a}$	[*,0]
$e_6 : 0 = x_2 - \bar{x}_2 - f_{x_2}$	[*,*]
$e_7 : 0 = x_3 - \bar{x}_3 - f_{x_3}$	[*,*]

Die Schaltzustände beziehungsweise Bedingungen, für die die Gleichungen  $e_{\{1,\dots,7\}}$  gelten, sind rechts angegeben. Die bekannten Variablen sind  $\mathbb{K} = \{\bar{a}, \bar{b}, \bar{x}_2, \bar{x}_3\}$ . Es soll die kleinste MSO-Teilmenge erzeugt werden, die den Fehler  $f_{x_3}$  enthält.

**Schritt 1:**  $f_{x_3}$  tritt nur in Gleichung  $e_7$  auf.  $x_3$  ist die einzige nicht besuchte Variable in  $e_7$ . Tabelle 5.2 zeigt die Daten des Algorithmus, die in Schritt 1 gespeichert sind. Da  $e_7$  für alle Schaltzustände im System gültig ist, werden keine zusätzlichen Bedingungen benötigt ([\*,\*]). Eq<sub>aux</sub> sind Hilfsgleichungen, die benötigt werden, um das Best-Case-MSO-Subsystem für jede besuchte Variable zu berechnen. Für jede besuchte, aber nicht verarbeitete Variable  $x_i$  führt der Algorithmus eine temporäre Hilfsgleichung  $e_{\text{aux},x_i} : x_i = \bar{x}_i$  ein, in der  $x_i$  die neu entdeckte Variable und  $\bar{x}_i$  ihr bekannter Wert ist. Die Hilfsgleichung Eq<sub>aux</sub> repräsentiert, dass  $x_i$  eine gemessene Variable ist, also sein Best-Case-Szenario. Wird die Variable verarbeitet, so aktualisiert der Algorithmus diese Annahme. In Schritt 1 ist die beste Annahme für  $x_3$ , dass  $x_3$  im System gemessen wird, dargestellt durch die Hilfsgleichung  $e_{\text{aux},x_3} : x_3 = \bar{x}_3$ , wobei  $\bar{x}_3$  ein bekannter Wert ist. Die Gleichung  $e_{\text{aux},x_3}$  ist in der Spalte Eq<sub>aux</sub> in Tabelle 5.2 gespeichert. Die aktuell beste Schätzung für ein MSO-Subsystem, das  $f_{x_3}$  enthält, ist also  $\{e_7, e_{\text{aux},x_3}\}$  mit der Kardinalität  $|\{e_7, e_{\text{aux},x_3}\}| = 2$ .  $x_3$  ist Teil von MSO<sub>temp</sub>, weshalb es mit der entsprechenden Kardinalität gewichtet wird. Abbildung 5.5, Schritt 1 zeigt den Fortschritt des Algorithmus nach dem ersten Schritt.

**Schritt 2:** Für den nächsten Schritt wählt der Algorithmus die besuchte Variable mit den geringsten Kosten (kleinste MSO-Kardinalität). Da  $x_3$  die einzige besuchte Variable ist, fällt

Schritt 1	Schritt 2	
Bed. $[*, *]$	Bed. $[*, *]$	Bed. $[1, *]$
$f_{x_3} - e_7 - \mathbf{x_3} - e_{\text{aux},x_3}$	$f_{x_3} - e_7 - x_3$	$f_{x_3} - e_7 - x_3 - e_2 - \mathbf{x_2} - e_{\text{aux},x_2}$
	Bed. $[0, *]$	Bed. $[*, 0]$
	$f_{x_3} - e_7 - x_3 - e_3 - \mathbf{x_1} - e_{\text{aux},x_1}$	$f_{x_3} - e_7 - x_3 - e_5 - \mathbf{x_1} - e_{\text{aux},x_1}$
	Bed. $[0, 0]$	Bed. $[1, 0]$

**Abbildung 5.5:** Visualisierung der Schritte des Greedy-Algorithmus zum Finden der MSO-Teilsysteme mit den wenigsten Gleichungen für das Beispielsystem 5.1. Besuchte Variablen sind in Rot und Hilfsgleichungen in Grau markiert. Der Abbruchschritt ist mit einem grauen Feld markiert.

die Wahl auf  $x_3$ . Abbildung 5.5, Schritt 2 und Tabelle 5.3 zeigen den Explorationsstatus unter den verschiedenen Bedingungen.  $x_3$  ist Teil von  $e_2$ ,  $e_3$  und  $e_5$ . Ausgehend von  $f_{x_3}$  lässt sich nur  $x_3$  über  $e_7$  unter der Bedingung  $[*, *]$  erreichen.  $e_2$  erfordert, dass der erste Schalter geschlossen ist ( $[1, *]$ ). Dieser Weg ist erlaubt, da kein spezieller Schalterzustand nötig ist, um  $x_3$  ausgehend von  $f_{x_3}$  zu erreichen. Daher fügt der Algorithmus die Variable  $x_2$  als neue besuchte Variable unter der Bedingung  $[1, *]$  hinzu. Ähnlich gilt  $e_3$  nur für  $[0, *]$  (erster Schalter offen). Daher ist  $x_1$  die einzige neue Variable in  $e_3$  und wird unter der Bedingung  $[0, *]$  zu den besuchten Variablen hinzugefügt. Mit  $e_5$  ist die Variable  $x_1$  außerdem unter der Bedingung  $[*, 0]$  zu erreichen. Kombiniert man die Bedingungen  $[0, *]$  und  $[*, 0]$  zu  $[0, 0]$ , so erreicht man  $x_1$  sowohl über  $e_3$  als auch über  $e_5$ . Analog führt die Kombination von  $[1, *]$  und  $[*, 0]$  dazu, dass  $x_2$  und  $x_1$ , unter der Bedingung  $[1, 0]$ , von  $e_2$  beziehungsweise  $e_5$  erreicht werden können. Der Algorithmus terminiert, da die MSO-Menge  $\{e_7, e_3, e_5\}$  ohne Hilfsgleichung gefunden wurde und keine MSO-Set-Schätzung eine kleinere Kardinalität besitzt.

Das Beispiel lässt sich an den formalen Beschreibungen der Algorithmen 5.1, 5.2 und 5.3 nachvollziehen: In Algorithmus 5.1, Zeile 7 resultiert  $Equations = \{e_2, e_3, e_5, e_7\}$ . Das Verfahren ignoriert  $e_7$  in  $Equations$ , da  $e_7$  bereits verarbeitet wurde (Algorithmus 5.2, Zeile 10). Die neue Bedingung  $Bcom$  bei der Verarbeitung von  $e_2$  ist die Kombination von  $[*, *]$  und  $[1, *]$ , also  $[1, *]$ .  $[1, *]$  wird der Liste der Bedingungen  $\mathbb{B}$  (Algorithmus 5.2, Zeile 7) und  $x_2$  der Liste der besuchten Variablen hinzugefügt:  $visitedVars = \{x_2\}$ . Die Kombination von  $V.Requirements = \{[*, *], [1, *]\}$  mit der Bedingung von  $e_3$   $[0, *]$  ergibt  $[0, *]$ . Das Verfahren ergänzt die Variable  $x_1$  in den besuchten Variablen  $visitedVars = \{x_2, x_1\}$ . Bei der Verarbeitung von  $e_5$  erfolgt eine Kombination von  $[*, 0]$  mit  $V.Requirements = \{[*, *], [1, *], [0, *]\}$  zu  $\mathbb{B} = \{[*, 0], [0, 0], [1, 0]\}$ .  $x_1$  ist bereits Teil von  $visitedVars$ . Ähnlich wie in Schritt 1 berechnet das Verfahren für jede Bedingung die untere Schranke für die kleinste MSO-Set-Schätzung mittels Algorithmus 5.3 (siehe Tabelle 5.3).

**Tabelle 5.3:** Gespeicherte Daten des Algorithmus nach Schritt 2. Das resultierende MSO-Teilsystem und der Abbruchschritt sind mit einem grauen Feld markiert.

Bed.	Gleichungen	Var <sub>visited</sub>	Eq <sub>aux</sub>	MSO <sub>temp</sub>
[*, *]	$e_7$			$\emptyset$
[1, *]	$e_7, e_2$	$x_2$	$e_{aux,x_2}$	$\{e_7, e_2, e_{aux,x_2}\}$
[0, *]	$e_7, e_3$	$x_1$	$e_{aux,x_1}$	$\{e_7, e_3, e_{aux,x_1}\}$
*, 0]	$e_7, e_5$	$x_1$	$e_{aux,x_1}$	$\{e_7, e_5, e_{aux,x_1}\}$
[0, 0]	$e_7, e_3, e_5$	$x_1$	$e_{aux,x_1}$	$\{e_7, e_3, e_5\}$
[1, 0]	$e_7, e_2, e_5$	$x_2, x_1$	$e_{aux,x_2}, e_{aux,x_1}$	$\{e_7, e_2, e_{aux,x_2}\}$


**Bemerkung 5.1.** Auf den ersten Blick mag dies wie ein exponentielles Wachstum der möglichen Schaltzustände und damit der Rechenressourcen erscheinen. Bei näherer Betrachtung kann man jedoch feststellen, dass alle Gleichungen und alle besuchten Variablen der ersten vier Bedingungen in Tabelle 5.3 Teil der letzten beiden Bedingungen sind. Daher gibt die kleinste MSO-Set-Schätzung der beiden letztgenannten Bedingungen eine untere Schranke für die Kardinalität der Best-Case MSO-Set-Schätzung für die oberen vier Bedingungen. Unter Berücksichtigung dieser Schätzungen muss MSO<sub>temp</sub> für die ersten vier Bedingungen nicht berechnet werden.

## 5.4 Anwendung auf das rekonfigurierbare Batteriemodul

Der Algorithmus zum Finden der MSO-Sets mit den wenigsten Gleichungen wird auf das in Abschnitt 5.2 vorgestellte RBS mit sechs Zellen in 2s3p-Konfiguration angewandt. Abschnitt 5.4.1 stellt die resultierenden MSO-Sets für das Batteriemodul vor. Ein experimenteller Versuchsaufbau (Abschnitt 5.4.2) zeigt die Anwendbarkeit der MSO-Sets zur Residuengenerierung anhand eines exemplarischen Fehlers (Abschnitt 5.4.3). Abschnitt 5.4.4 vergleicht den vorgestellten Ansatz in Form einer Komplexitätsanalyse mit bekannten Ansätzen der Literatur.

### 5.4.1 Resultierende minimale strukturell überbestimmte Teilsysteme

Basierend auf den Gleichungen aus Tabelle 5.1 liefert der im vorangegangenen Abschnitt 5.3.2 vorgestellte Algorithmus MSO-Teilsysteme für alle 74 berücksichtigten Fehler  $f_\theta$  aus Abbildung 5.4. Während für die strukturelle Analyse die Leistungsschalter als schaltbare Widerstände modelliert wurden, stellt ein geöffneter Schalter im Rahmen der aktiven Fehlerdiagnose einen idealen Leerlauf dar. Zur Berücksichtigung von Fehlern an geöffneten Schaltern werden



**Abbildung 5.6:** MSO-Teilsysteme mit der geringsten Anzahl von Gleichungen für jeden Fehler: Die Fehler sind auf der Ordinate und die Gleichungen aus Tabelle 5.1 auf der Abszisse dargestellt (zusammengefasst durch  $i = 1, \dots, 6$ ). Ein schwarzes Quadrat bedeutet, dass die Gleichung zu der jeweiligen MSO-Menge des Fehlers gehört. Der experimentell untersuchte Fehler  $f_{\hat{i}_{byp,off,2}}$  ist blau hervorgehoben.


die Leckströme  $f_{\hat{i}_{\text{act,off},i}}$  und  $f_{\hat{i}_{\text{byp,off},i}}$  als zusätzliche Fehler eingeführt, sodass 86 mögliche Fehler resultieren. Abbildung 5.6 zeigt auf der Abszisse alle berücksichtigten Fehler und entlang der Ordinate die Gleichungen aus Tabelle 5.1. Ein schwarzes Quadrat kennzeichnet für jeden Fehler diejenigen Gleichungen, die für das kleinste MSO-Teilsystem benötigt werden. Die gefundenen MSO-Mengen, bestehend aus einer Untermenge an Gleichungen, erfordern bestimmte Schalt-Konfigurationen im System, um gültig zu sein. Diese führt die Fehlerdiagnose entweder aktiv herbei oder kombiniert sie mit anderen Algorithmen wie beispielsweise dem Balancing.

Betrachtet man die Modellgleichungen  $e_{\{1,\dots,16\},i}$ , so ist zu beobachten, dass der Algorithmus die Gleichungen des thermischen Modells  $e_{\{11,\dots,14\},i}$  nur in den MSO-Sets zur Diagnose der Temperatursensoren  $T_{s,i}$  berücksichtigt. Dies erklärt sich durch den differentiellen Zusammenhang über die Wärmegenerierung zwischen den elektrischen und thermischen Größen. MSO-Subsysteme mit den thermischen Gleichungen bestehen aus mehr Gleichungen und haben daher größere Modellunsicherheiten. Daher priorisiert der Algorithmus MSO-Subsysteme ohne thermische Gleichungen. Die Diagnose der Stromsensoren  $i_{\text{cell},i}$  und der Spannungssensoren  $v_{\text{cell},i}$  erfolgt, während der zugehörige AS geöffnet ist. Für den Spannungssensor kommt aufgrund der Zelldynamik die Systemgleichung  $e_{2,i}$  der Zelle hinzu. Fehler innerhalb der Zelle, wie  $f_{E_{m,i}}$ ,  $f_{R_{o,i}}$ ,  $f_{C_{p,i}}$  und  $f_{R_{p,i}}$ , isoliert der Algorithmus nur durch die zellspezifischen Strom- und Spannungssensoren und entsprechende Schaltzustände ( $e_{\{1,\dots,4\},i}$ ). Dies ist intuitiv, da über die Sensoren der benachbarten Zellen zusätzliche Modellunsicherheiten hinzukommen würden. Die Diagnose von Schaltern, Kontaktwiderständen und Stromschienen erfolgt über ähnliche Teilmengen von Gleichungen. Zu den zellspezifischen Sensoren und Schaltern kommen jedoch auch die Sensoren der benachbarten Zellen ( $e_{15,i}$ ) und der Gesamtspannungssensor ( $e_{16}$ ) zur Diagnose der Variablen hinzu.

### 5.4.2 Versuchsaufbau

Der in Abbildung 5.7 gezeigte experimentelle Versuchsaufbau ermöglicht die Validierung des vorgestellten Verfahrens. Die Beschreibung der zugehörigen Komponenten liefert Tabelle 5.4. Für die Versuche kommt die in Tabelle 2.1 vorgestellte zylindrische SMG-Zelle zum Einsatz (Abbildung 5.7i). Stromschienen verbinden sechs Zellen gemäß dem elektrischen Ersatzschaltbild aus Abbildung 5.2 zu einem 2s3p-Modul (siehe Abbildung 5.7g). Die Tests erfolgen in einer Temperaturkammer bei einer konstanten Temperatur von 25 °C. Ein Chroma-Modultester dient als Quelle und Last, um das Modul mit einem dynamischen Stromprofil, basierend auf dem WLTP-Fahrzyklus, anzuregen. Der Tester liefert zudem eine Messung des Gesamtstroms und der Gesamtspannung mit einer Zeitauflösung von 40 ms. Die zur Fehlerdiagnose verwendeten Signale messen die Sensoren einer an die Zellterminals angeschlossenen Leiterplatte mit einer zeitlichen Auflösung von 80 ms. Neben den Sensoren enthält die Platine auch die beiden Schalter, die als Leistungs-MOSFETs realisiert sind. Die Lithium-Ionen-Zelle selbst






**Abbildung 5.7:** Experimenteller Aufbau des RBS-Moduls. Die Beschreibung der Komponenten liefert Tabelle 5.4. Das zugehörige Ersatzschaltbild zeigen die Abbildungen 5.1 und 5.2.

**Tabelle 5.4:** Beschreibung der Komponenten des Versuchsaufbaus in Abbildung 5.7.

(a)	Sicherung
(b)	Anzeige-LED für den Zustand des PCBs
(c)	Anzeige-LED für den Active-Schalter
(d)	Anzeige-LED für die externe Stromversorgung
(e)	Externe Stromversorgung für das PCB
(f)	Stecker und Kabel zum Datenlogger
(g)	Stromschienen, mit Schraubenmuttern befestigt
(h)	Anschluss von Power- und Sense-Leitung
(i)	Lithium-Ionen-Zelle
(j)	Temperatursensor

ist an eine weitere Leiterplatte gelötet. Diese Adapter-Leiterplatte dient als mechanischer Zellhalter, verfügt aber darüber hinaus auch über eine Sicherung (Abbildung 5.7a) und Referenzsensoren zur Spannungs-, shuntbasierten Strom- und Temperaturmessung der Zelle. Abbildung 5.7j kennzeichnet die Position der Temperaturmessung. Die Aufzeichnung der Referenzsensoren erfolgt durch einen Datenlogger (Hioki 8423) mit einer zeitlichen Auflösung von 10 ms (Abbildung 5.7f). Um die Messungen nicht zu beeinflussen, versorgt eine externe



**Abbildung 5.8:** Experimentelle Ergebnisse für den emulierten Fehler  $f_{\hat{i}_{byp,off,2}}$ . Von oben nach unten: gemessene Zellströme  $\hat{i}_{cell,i}$ , Zellspannungen  $\bar{v}_{cell,i}$ , Zelltemperaturen  $\bar{T}_{cell,i}$  und Wert der Residuen  $r$ .

Quelle die Leiterplatten (siehe Abbildung 5.7e). Aufgrund der unterschiedlichen Abtastzeiten werden alle Messungen zeitlich synchronisiert. Die Schrittweite der Algorithmen, die an diesem Versuchsaufbau validiert werden, beträgt  $\Delta t = 0.96$  s. Diese Schrittweite bietet sich aufgrund der unterschiedlichen Abtastraten von 10 ms, 40 ms und 80 ms der Sensorsysteme an. Die Referenzsensoren dienen ausschließlich der Kalibrierung.

### 5.4.3 Experimentelle Validierung

Die Validierung des vorgestellten Algorithmus erfolgt an dieser Stelle exemplarisch anhand eines *Stuck-Closed*-Fehlers im Bypass-Schalter der Zelle  $i = 2$ . Weitere Fehler, basierend auf diesem Versuchsaufbau, untersucht Abschnitt 5.7.2. Der emulierte Fehler im Bypass-Schalter entspricht dem in Abbildung 5.6 blau markierten Fehler  $f_{\hat{i}_{byp,off,2}}$ . Anstatt im offenen Zustand hochohmig zu werden, zeigt der fehlerhafte Bypass-Schalter im offenen Zustand einen Widerstand von  $3.3\Omega$ . Der Fehler wird zum Zeitpunkt  $t = 610$  s emuliert. Abbildung 5.8


zeigt untereinander die gemessenen Ströme, Spannungen, Temperaturen der einzelnen Zellen. Darunter folgen die Residuen für jeden Fehler, die aus den in Abbildung 5.6 dargestellten MSO-Sets gebildet werden. Da die Berechnung der MSO-Sets und die Generierung der Residuen auf Basis der Systemgleichungen im Vorfeld offline erfolgt, muss diese Aufgabe für jedes System nur einmal durchgeführt werden. Die Online-Fehlerdiagnose selbst mit Hilfe der Residuen erfordert wenig Rechenaufwand und ist daher echtzeitfähig. Der fehlerhafte Schalter führt zu einem zusätzlichen Stromfluss von etwa 1 A, der sich auf die drei Zellen  $i \in \{1, 2, 3\}$  aufteilt (siehe den um 0.33 A geringeren Zellstrom in Abbildung 5.8a). In Abbildung 5.8b ist eine niedrigere Spannung der Zellen  $i \in \{1, 2, 3\}$  im Vergleich zu den Zellen  $i \in \{4, 5, 6\}$  zu beobachten. Dies ist auf die zusätzliche Belastung der Zellen  $i \in \{1, 2, 3\}$  und den daraus resultierenden Spannungsabfall sowie deren schnellere Entladung zurückzuführen. Die Temperatur bleibt weitgehend unverändert. Der emulierte Fehler bei  $t = 610$  s bewirkt, dass das Residuum

$$\overline{i_{\text{total}}} - \sum_{j=1}^3 \overline{i_{\text{cell},j}} \neq 0 \quad (5.293)$$

für den Fehler  $f_{\widehat{i}_{\text{byp,off},2}}$  ungleich Null wird. Dabei sind  $\overline{i_{\text{total}}}$  und  $\overline{i_{\text{cell},j}}$  die bekannten, gemessenen Größen der entsprechenden Sensoren. (5.293) ist ungleich Null, da ein zusätzlicher Strom auftritt, der vom Sensor  $\overline{i_{\text{total}}}$  nicht gemessen wird. Dementsprechend ist in Abbildung 5.8d eine signifikante Abweichung des Residuums für den Fehler  $f_{\widehat{i}_{\text{byp,off},2}}$  zu beobachten. Im Allgemeinen könnte der emulierte Fehler zu weiteren von Null abweichenden Residuen führen, sofern der Strom  $\widehat{i}_{\text{byp,off},2}$  enthalten ist. In diesem Fall ist jedoch nur für ein Residuum eine deutliche Abweichung von Null zu beobachten. Damit bestätigt sich die Annahme, dass das MSO-Subsystem mit der kleinsten Anzahl von Gleichungen auch eine gute Empfindlichkeit gegenüber dem Fehler aufweist.

#### 5.4.4 Diskussion und Komplexitätsanalyse

Im Folgenden wird die Rechenkomplexität für die Berechnung der MSO-Teilmengen im Vergleich zu bestehenden Algorithmen diskutiert, die alle MSO-Teilmengen eines Systems berechnen [92, 152, 222, 280]. Abbildung 5.9 zeigt in blau die Anzahl der Schritte, die der in Abschnitt 5.3.2 vorgestellte Algorithmus abhängig von der Systemgröße für jeden Fehler benötigt. Die untersuchten Systemgrößen umfassen Batteriepacks mit  $s \in [2, 32]$  seriellen und  $p \in [3, 6]$  parallelen Zellen. Dabei ist ein Schritt definiert als jedes Durchlaufen der Zeile 5 im Algorithmus 5.1. Es ist zu sehen, dass die Anzahl der Schritte für die meisten Fehler unabhängig von der Anzahl der Zellen im System ist. Dies ist einer der Vorteile des entwickelten Algorithmus, der aufgrund des *Bottom-Up*-Ansatzes inhärent lokal auf den untersuchten Fehler beschränkt ist. Findet das Verfahren eine MSO-Teilmenge in der Nähe des zu untersuchenden Fehlers, so bricht es schnell ab und muss den Rest des Systems nicht berücksichtigen. Bei Fehlern, die Kenntnisse über das gesamte System erfordern, wie



**Abbildung 5.9:** Komplexitätsanalyse für Batteriesysteme: Vom Algorithmus benötigte Schritte zur Berechnung der MSO-Sets in Abhängigkeit von der Anzahl der parallelen ( $p$ ) und seriellen ( $s$ ) Zellen (blau) und untere Schranke für die Anzahl der von den bestehenden Algorithmen berechneten MSO-Sets (schwarz).

beispielsweise Fehler im Gesamtspannungs- oder Stromsensor oder Fehler der Stromschienen zwischen den Zeilen, muss der Algorithmus jedoch alle Gleichungen im System berücksichtigen, was zu einer erhöhten Rechenlast führt. Für Systeme ohne Validitätsbedingungen in den Gleichungen, wie es in konventionellen Batteriesystemen der Fall ist, ist der Engpass die Kombination von Basis-MSO-Sets in Zeile 8 des Algorithmus 5.3. Durch die Begrenzung der Anzahl der zu kombinierenden Basis-MSO-Sets auf  $n = 1$  (siehe Abschnitt 5.3.2) lässt sich dieser Engpass zwar überwinden, es wird jedoch etwas wahrscheinlicher, dass das resultierende MSO-Set nicht mehr das kleinste MSO-Set für den untersuchten Fehler ist. In Abbildung 5.9 sind die resultierenden Schrittzahlen für eine Heuristik von  $n = 1$  mit gestrichelten Linien eingezeichnet.

Bei Systemen mit Validitätsbedingungen, wie RBSs, tritt ein weiterer Engpass auf: Die Anzahl der im Algorithmus gespeicherten Bedingungen kann für die nichtlokalen Fehler, beispielsweise  $f_{v_{total}}$  oder  $f_{i_{total}}$ , sehr schnell wachsen. Obwohl nicht alle MSO-Mengen ausgewertet werden müssen (siehe Bemerkung 5.1), kann dies schnell zu Speicherproblemen führen. Jeder Active- und Bypass-Schalter jeder Zelle hat drei mögliche Bedingungen (I): geschlossen (1), offen (0) oder *Don't-Care* (\*). Einige Bedingungen sind nicht gültig, da nicht alle Zellen im Bypass-Modus sein können (II) und nicht alle Zellen in einer Reihe im *Idle*-Zustand sein dürfen (III). Zudem darf, wenn eine Zelle in einer Reihe im Active-Modus ist, keine der anderen Zellen in derselben Reihe im Bypass-Modus sein (IV). Jede Zeile hat

also

$$n_{\text{row}}(p) = \underbrace{3^{2p}}_{\text{I}} - \underbrace{\sum_{i=1}^p \left( \binom{p}{i} \sum_{j=1}^p \binom{p}{j} \right)}_{\text{IV}} - \underbrace{1}_{\text{III}} \quad (5.294)$$

verschiedene mögliche Bedingungen. Bei  $s$  Zeilen ergeben sich daraus insgesamt

$$n_{\text{Bed.}}(s, p) = (n_{\text{row}}(p))^s - \underbrace{1}_{\text{II}} \quad (5.295)$$

unterschiedliche Bedingungen. Die rechnerischen Einschränkungen sollten jedoch im Zusammenhang mit den herkömmlichen Algorithmen gesehen werden, die alle MSO-Mengen im System berechnen [92, 152, 222, 280]. Die genaue Anzahl aller MSO-Sets im System ist analytisch schwer zu berechnen. Allerdings lässt sich eine untere Schranke für ein RBS mit  $p$  parallelen und  $s$  seriellen Zellen abschätzen. Die Abschätzung basiert auf der Annahme, dass aus jeder Gleichung, die zwei Sensoren enthält, mindestens eine MSO-Menge resultiert (beispielsweise nach den Kirchhoffschen Gesetzen). Diese untere Grenze ist als schwarz gestrichelte Linie in Abbildung 5.9 dargestellt. Es ist zu beobachten, dass die Gesamtzahl der MSO-Sets im System schnell die Anzahl der Schritte übersteigt, die der in dieser Arbeit vorgeschlagene Algorithmus benötigt. Dies führt zu der Schlussfolgerung, dass für Systeme mit einer großen Redundanz, wie das in Abschnitt 5.2 vorgestellte RBS, der in dieser Arbeit vorgestellte *Bottom-Up*-Ansatz rechnerisch deutlich effizienter ist als herkömmliche Algorithmen, die alle MSO-Sets im System berechnen, obwohl nur sehr wenige tatsächlich für die Fehlerdiagnose benötigt werden. Für kleinere Systeme mit geringerer Redundanz kann der Einsatz der konventionellen Algorithmen von [92, 152, 222, 280] jedoch trotzdem einen geringen Rechenbedarf und damit eine sinnvolle Alternative darstellen.

## 5.5 Residuenbasierte Parameterschätzung

Basierend auf den gefundenen MSO-Teilmengen generiert dieser Abschnitt Residuen für die Fehlerdiagnose. Abschnitt 5.5.1 stellt die implementierten Residuen vor, die die aktive Fehlerdiagnose verwendet. Basierend auf diesen Residuen kalibriert ein beschränktes SPKF das System während des fehlerfreien Betriebs.

### 5.5.1 Implementierte Residuen

Der in Abschnitt 5.3 vorgestellte Algorithmus berechnet die zehn kleinsten MSO-Teilsysteme für alle Fehler im System. Basierend auf den resultierenden MSO-Mengen lässt sich ein Residuum für jeden Fehler implementieren. Das kleinste MSO-Teilsystem mit den Fehlern  $f_{R_{\text{con},i}}$  und  $f_{R_{\text{act,on},i}}$  ist eine Masche, basierend auf dem KVL, mit der nächsten Zelle. Die zweitkleinste Menge ist eine KVL-Masche mit der nicht-benachbarten Zelle, während sich

die Zelle dazwischen im *Idle*-Zustand befindet. Für beide MSO-Mengen werden Residuen implementiert, um die Isolierbarkeit durch aktive Fehlerdiagnose zu verbessern. Das kleinste MSO-Teilsystem, das  $f_{R_{o,i}}$  enthält, besteht aus den Gleichungen, die das dynamische Verhalten der Zelle beschreiben. Das zugehörige Residuum wird mit Hilfe eines adaptiven Kalman-Filters implementiert. Der *Expectation–Maximization*-Algorithmus von Bavdekar, Deshpande und Patwardhan identifiziert dabei das Prozess- und Messrauschen des Kalman-Filters [13]. Die Fehler  $f_{E_{m,i}}$  und  $f_{v_{cell,i}}$  wertet die Implementierung durch Öffnen des ASs der jeweiligen Zelle aus, sodass sich die externe Anregung der Zelle vernachlässigen lässt. Fehler in den Stromsensoren  $f_{i_{cell,i}}$  evaluiert der Algorithmus durch Öffnen des ASs. Dann folgt  $i_{cell,i} \approx 0$ . Die kleinste MSO-Menge für  $f_{i_{total}}$  und Fehler in  $R_{byp,off}$  basieren auf dem KCL für jede Zeile im Batteriesystem  $i_{total} = \sum_{k=1}^{n_{par}} i_{cell,k}$ . Ein Fehler im Gesamtspannungssensor  $f_{v_{total}}$  und Fehler in den Stromschienen  $R_{bp,i}, i \in \{1, 4\}$  und  $R_{bn,i}, i \in \{3, 6\}$  werden durch eine KVL-Masche über das gesamte Modul diagnostiziert, während sich alle Zellen im Active-Zustand befinden.

Inspiziert von Gustafsson verwendet auch diese Arbeit einen normalisierten Residuenraum [101]. Dabei wird angenommen, dass die Residuen Gauß-verteilt mit einer bekannten Varianz  $\Sigma_{\tilde{r}}$  sind. Dies erfordert Gauß-verteilt Prozess- und Messrauschen, wie es auch in der Literatur oft angenommen wird [44, 93, 103, 134, 194]. Der normierte Residuenraum ist dann eine lineare Transformation

$$\mathbf{r} = \mathbf{L}^T \tilde{\mathbf{r}} \quad (5.296)$$

mit  $\mathbf{L} = (\text{chol}(\Sigma_{\tilde{r}}))^{-1}$ , dem Residuenvektor  $\tilde{\mathbf{r}}$  und der Cholesky-Zerlegung  $\text{chol}(\cdot)$ . Die resultierenden, normalisierten Residuen  $\mathbf{r} \in \mathbb{R}^n$  sind unabhängig normalverteilt. Dies vereinfacht die Fehlerdetektion und erhöht die Fehlerempfindlichkeit.

### 5.5.2 Beschränkter Parameter-Schätzer

Modellunsicherheiten können die Leistungsfähigkeit eines modellbasierten Fehlerdiagnose-Ansatzes verschlechtern [17]. Aus diesem Grund kommt ein Parameterschätzer für die Systemkalibrierung zum Einsatz, um die Modellunsicherheiten zu verringern. Aufgrund der Nichtlinearitäten im betrachteten System (siehe Abschnitt 2.4.7) wird ein SPKF implementiert. In der Literatur ist eine gängige Wahl für die Implementierung des Square-Root-SPKF von van der Merwe und Wan, den auch Plett auf Lithium-Ionen-Zellen anwendet [218, 283]. Für die vorliegende Anwendung stößt das Square-Root-SPKF jedoch auf numerische Probleme. Daher kommt im Rahmen dieser Arbeit das von Chen vorgeschlagene SVD-basierte SPKF für die Parameterschätzung zum Einsatz (siehe Algorithmus 5.4) [30].

Die SVD-basierte Implementierung erweist sich für das betrachtete System als stabil. Die Rechenkomplexität des Filters erhöht sich dadurch jedoch auf  $\mathcal{O}(N^3)$  im Vergleich zu  $\mathcal{O}(N^2)$  für das Square-Root-SPKF [30, 218]. Das Ziel des SVD-basierten SPKF's ist es, die fehlerfreien Residuen auf Null zu bringen (siehe Algorithmus 5.4, Zeile 21). Um die numerische Stabilität zu erhöhen, werden die geschätzten Parameter auf den erwarteten Parameterwert

**Algorithmus 5.4** SVD-basiertes SPKF [30, 320]

- System
- 1:  $\boldsymbol{\theta}_k = \boldsymbol{\theta}_{k-1} + \boldsymbol{\omega}_{k-1} \quad \boldsymbol{\omega} \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\Sigma}_\omega)$
  - 2:  $\mathbf{d}_k = \mathbf{r}(\mathbf{x}_k, \mathbf{u}_k, \boldsymbol{\theta}_k) + \boldsymbol{\nu}_k \quad \boldsymbol{\nu}_k \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$
- Beschränkungen
- 3:  $\hat{\boldsymbol{\theta}}_k > \mathbf{0}$
  - 4:  $\hat{\boldsymbol{\theta}}_k \approx \hat{\boldsymbol{\theta}}_0 + \boldsymbol{\xi}_\theta \quad \boldsymbol{\xi}_\theta \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\Sigma}_\xi)$
- Definitionen
- 5:  $N_\theta = \dim(\boldsymbol{\theta}_k)$
  - 6:  $\gamma : 1 \leq \gamma \leq \sqrt{2}$
  - 7:  $\alpha_i^{(m)} = \frac{1}{2N_\theta} \quad 1 \leq i \leq N_\theta$
  - 8:  $\alpha_0^{(c)} = \frac{\kappa}{N_\theta + \kappa}$
  - 9:  $\alpha_i^{(c)} = \frac{1}{2N_\theta + 2\kappa} \quad 1 \leq i \leq N_\theta$
- Initialisierung
- 10:  $\hat{\boldsymbol{\theta}}_0 = E[\boldsymbol{\theta}_0]$
  - 11:  $\hat{\mathbf{P}}_0 = E[(\boldsymbol{\theta}_0 - \hat{\boldsymbol{\theta}}_0)(\boldsymbol{\theta}_0 - \hat{\boldsymbol{\theta}}_0)^T]$

Schleife: for  $k \in \{1, 2, \dots, \infty\}$

Zeitupdate und Sigma-Punkt-Berechnung

- 12:  $\hat{\boldsymbol{\theta}}_k^- = \hat{\boldsymbol{\theta}}_{k-1}$
- 13:  $\mathbf{P}_{k|k-1} = \mathbf{P}_{k-1} + \boldsymbol{\Sigma}_\omega$
- 14:  $[\mathbf{U}, \mathbf{S}, \mathbf{V}] = \text{SVD}(\mathbf{P}_{k-1})$
- 15:  $\mathbf{W}_{k|k-1} = \begin{bmatrix} \hat{\boldsymbol{\theta}}_k^- & \hat{\boldsymbol{\theta}}_k^- + \gamma \mathbf{U} \sqrt{\mathbf{S}} & \hat{\boldsymbol{\theta}}_k^- - \gamma \mathbf{U} \sqrt{\mathbf{S}} \end{bmatrix}$
- 16:  $\mathbf{D}_{k|k-1} = \begin{bmatrix} \mathbf{r}(\mathbf{x}_k, \mathbf{u}_k, \mathbf{W}_{k|k-1}) \\ \frac{\mathbf{w}_{k|k-1} - \hat{\boldsymbol{\theta}}_0}{\hat{\boldsymbol{\theta}}_0} \end{bmatrix}$
- 17:  $\hat{\mathbf{d}}_k = \mathbf{D}_{k|k-1,0} + \sum_{i=1}^{2N_\theta} \alpha_i^{(m)} (\mathbf{D}_{k|k-1,i} - \mathbf{D}_{k|k-1,0})$

Messupdate

- 18:  $\mathbf{P}_{\hat{\mathbf{d}}_k, \hat{\mathbf{d}}_k} = \sum_{i=0}^{2N_\theta} \alpha_i^{(c)} (\mathbf{D}_{k|k-1,i} - \hat{\mathbf{d}}_k)(\mathbf{D}_{k|k-1,i} - \hat{\mathbf{d}}_k)^T + \begin{bmatrix} \mathbf{I} \\ \boldsymbol{\Sigma}_\xi \end{bmatrix}$
- 19:  $\mathbf{P}_{\hat{\boldsymbol{\theta}}_k, \hat{\mathbf{d}}_k} = \sum_{i=0}^{2N_\theta} \alpha_i^{(c)} (\mathbf{W}_{i,k|k-1} - \hat{\boldsymbol{\theta}}_k^-)(\mathbf{D}_{i,k|k-1} - \hat{\mathbf{d}}_k)^T$
- 20:  $\mathbf{K}_k = \mathbf{P}_{\hat{\boldsymbol{\theta}}_k, \hat{\mathbf{d}}_k} \mathbf{P}_{\hat{\mathbf{d}}_k, \hat{\mathbf{d}}_k}^{-1}$
- 21:  $\hat{\boldsymbol{\theta}}_k = \hat{\boldsymbol{\theta}}_k^- + \mathbf{K}_k (\mathbf{0} - \hat{\mathbf{d}}_k)$
- 22:  $\hat{\boldsymbol{\theta}}_k (\hat{\boldsymbol{\theta}}_k < \mathbf{0}) = \hat{\boldsymbol{\theta}}_0 (\hat{\boldsymbol{\theta}}_k < \mathbf{0})$
- 23:  $\mathbf{P}_k = \mathbf{P}_{k|k-1} - \mathbf{K}_k \mathbf{P}_{\hat{\mathbf{d}}_k, \hat{\mathbf{d}}_k} \mathbf{K}_k^T$

normalisiert:

$$\widehat{\boldsymbol{\theta}}_k \approx \widehat{\boldsymbol{\theta}}_0 = \mathbf{1}. \quad (5.297)$$

Jede Zelle im Batteriesystem besitzt individuelle Parameter

$$CP_j \in \{E_{m,i}, R_{o,i}, C_{p,i}, R_{p,i} \mid i \in [1, 6]\}, j \in [1, 24] \quad (5.298)$$

zur Berücksichtigung von Parametervariationen. Darüber hinaus besitzen die Parameter ein SOC-Modell  $\overline{CP}_j(\text{SOC})$  für jeden Zellparameter:

$$\widehat{CP}_{k,j} = \underbrace{\widehat{\theta}_{k,j}}_{\approx 1} \cdot \overline{CP}_j(\text{SOC}). \quad (5.299)$$

Auch die Systemparameter

$$SP_j \in \{R_{\text{con},i}, R_{\text{bn},i}, R_{\text{bp},i}, R_{\text{act,on},i}, R_{\text{byp,off},i} \mid i \in [1, 6]\}, j \in [1, 30] \quad (5.300)$$

außerhalb der galvanischen Zelle, wie beispielsweise die Kontakt- und Stromschienenwiderstände sowie die Widerstände der Schalter, sind mit Unsicherheiten behaftet. Um den übermäßigen Gebrauch von Fallunterscheidungen zu vermeiden, wird angenommen, dass sich alle Zellen zu Beginn im *Active*-Zustand befinden. Daher können an den Schaltern nur die Fehler  $f_{R_{\text{act,on},i}}$  und  $f_{R_{\text{byp,off},i}}$  auftreten. Da weit mehr Parameter zu schätzen sind, als Messungen zur Verfügung stehen, erfolgt die Parameterschätzung mit einem beschränkten Ansatz. Jeder Parameter besitzt dabei eine weiche Beschränkung

$$\widehat{\boldsymbol{\theta}}_k \approx \widehat{\boldsymbol{\theta}}_0 + \boldsymbol{\xi}_\theta, \quad \boldsymbol{\xi}_\theta \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\Sigma}_\xi), \quad (5.301)$$

und eine harte Beschränkung

$$\widehat{\boldsymbol{\theta}}_k > \mathbf{0}. \quad (5.302)$$

Gleichung (5.301) hält jeden Parameter in der Region des Startwertes  $\widehat{\boldsymbol{\theta}}_0$ , der dem Initialwert, basierend auf der Durchschnittszelle, entspricht. Die Größe der Region lässt sich mit der Matrix  $\boldsymbol{\Sigma}_\xi$  anpassen. Analog zu [263], wird Gleichung (5.301) als zusätzliche Messung zum Parameterschätzer in Algorithmus 5.4, Zeile 16 hinzugefügt. Der Algorithmus berechnet in dieser Zeile die Residuen und die normierte Abweichung vom Startwert für die Sigma-Punkte  $\mathbf{W}_{k|k-1}$ . Diese Randbedingung stellt das Vorwissen über die Systemparameter dar. Eine Zellcharakterisierung, wie aus den Abschnitten 2.2.2 und 2.2.3 bekannt, ermittelt die durchschnittlichen Parameter der Zellen. Nach der Charakterisierung ist das System im Allgemeinen ausreichend gut initialisiert, sodass nur kleinere Parametervariationen zu kompensieren sind. Auch die Parameter der Elektronik auf der Leiterplatte lassen sich vorab Offline ermitteln. Lediglich die Kontaktwiderstände  $R_{c,i}$  jeder Zelle sind nicht messbar, da sie sich mit je-



dem Testaufbau ändern. Für  $R_{\text{con},i}$  entfällt deshalb die Beschränkung (5.301). Die harte Beschränkung (5.302) ist durch die physikalischen Eigenschaften der Parameter motiviert, da beispielsweise Widerstandswerte nicht negativ sein können. Algorithmus 5.4 verfügt in Zeile 22 über die harte Beschränkung (5.302), die, ähnlich zu [3, 263], durch eine Projektion in den Schätzraum realisiert ist. Sobald ein Parameter-Schätzwert  $\hat{\theta}_{k,j}$  unter Null fällt, wird er auf seinen Startparameter  $\hat{\theta}_{0,j}$  gesetzt. Dieses Verfahren gibt dem Parameterschätzer die Möglichkeit, alle Parameter so nachzustellen, dass  $\hat{\theta}_{k,j} \geq 0$  ist.

Für das vorliegende System erfolgt die Initialisierung von  $\Sigma_\omega$  als Diagonalmatrix, mit

$$\text{diag}(\Sigma_\omega) = \begin{cases} 5 \cdot 10^{-13} & \forall SP_j, CP_j \neq E_{m,i} \\ 5 \cdot 10^{-15} & \forall E_{m,i}. \end{cases} \quad (5.303)$$

Da  $R_{\text{act,on},i}$  weitgehend konstant bleibt und, im Gegensatz zu den Kontaktwiderständen, auf der Leiterplatte messbar ist, korrespondiert  $R_{\text{act,on},i}$  zu einem kleinen Wert auf der Diagonale von  $\Sigma_\xi$ . Die Prozessvarianz  $\Sigma_\omega$  ist ebenfalls eine Diagonalmatrix mit

$$\text{diag}(\Sigma_\omega) = \begin{cases} 5 \cdot 10^{-13} & \forall SP_j, CP_j \neq E_{m,i} \\ 5 \cdot 10^{-15} & \forall E_{m,i}. \end{cases} \quad (5.304)$$

Die Varianz der initialen Parameter  $\widehat{\mathbf{P}}_0$  beträgt

$$\text{diag}(\widehat{\mathbf{P}}_0) = \begin{cases} 5 \cdot 10^{-5} & \forall SP_j, CP_j \neq E_{m,i} \\ 5 \cdot 10^{-7} & \forall E_{m,i}. \end{cases} \quad (5.305)$$

Im betrachteten System wird  $\gamma = \sqrt{2}$  und  $\kappa = 3 - N_\theta$  gewählt. Die Anzahl der Parameter im 2s3p-System beträgt  $N_\theta = 54$ .

## 5.6 Fehlerdiagnose

Basierend auf der residuenbasierten Parameterschätzung aus Abschnitt 5.5, entwickelt dieser Abschnitt das in Abbildung 5.10 dargestellte Diagnose-Framework. Während das SPKF das Modell kontinuierlich kalibriert, überwacht ein  $\chi^2$ -Test die Residuen. Übersteigen die Residuen einen Schwellwert, erkennt das Verfahren einen Fehler (passive Fehlerdetektion) und isoliert diesen mit dem in Abschnitt 5.6.1 vorgestellten Fuzzy-Clustering-Ansatz. Um die Robustheit zu erhöhen, führt Abschnitt 5.6.2 ein Detektierbarkeitsmaß für die Fälle ein, in denen Fehler strukturell, aber nicht analytisch detektierbar sind. Abschnitt 5.6.3 stellt einen Ansatz zur aktiven Fehlerisolation vor, der die Richtung der Residuenvektoren nach Schaltaktion analysiert.

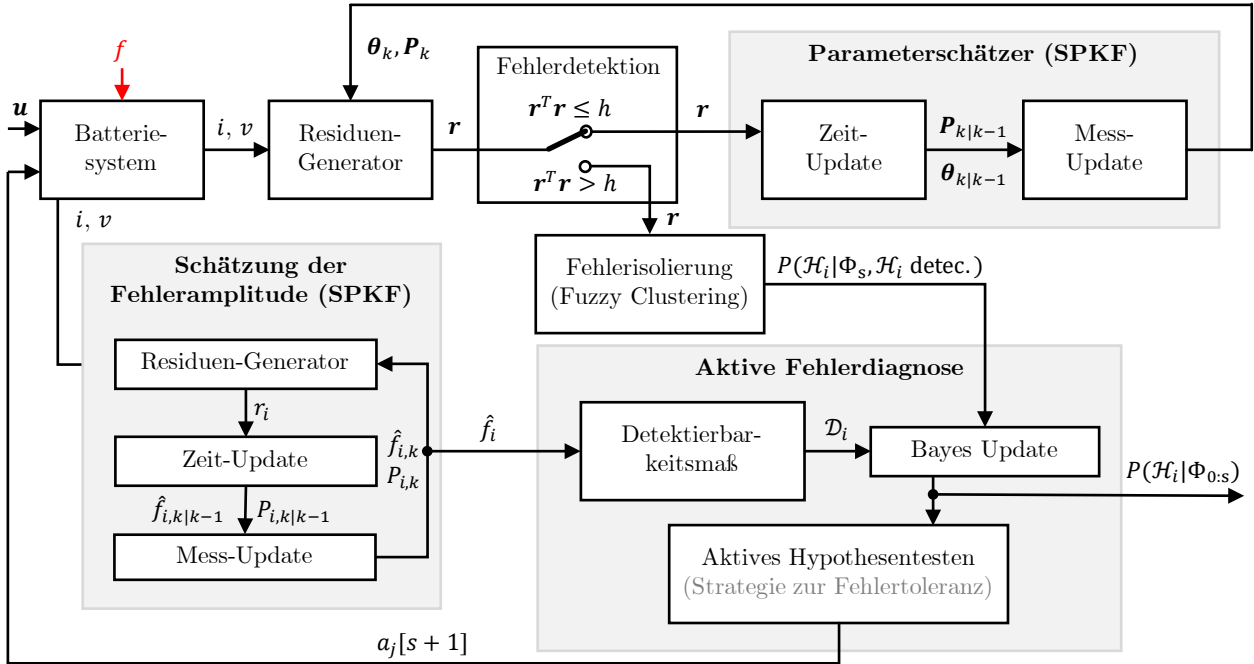


Abbildung 5.10: Framework zur aktiven Fehlerdiagnose.

### 5.6.1 Passive Fehlerdetektion und Isolation

Die Fehlerdetektion erfolgt mit einem  $\chi^2$ -Test. Im Folgenden wird das  $i$ -te Residuum zum Zeitpunkt  $k$  als  $r_i[k]$  bezeichnet. Nach Gleichung (5.296) ist  $r_i[k]$  annähernd unabhängig normalverteilt, weshalb die quadrierte Summe

$$g_{M,i}[k] = \sum_{j=k-M+1}^k r_i^2[j] \quad (5.306)$$

von  $r_i[k]$  über ein Zeitfenster mit der Länge  $M$  ungefähr der  $\chi^2$ -Verteilung

$$g_{M,i}[k] \sim \chi_M^2 \quad (5.307)$$

mit  $M$  Freiheitsgraden folgt. Ein größeres  $M$  führt zu einer höheren Verzögerung der Detektion, bietet aber eine bessere Sensitivität [17]. Die Wahl von  $M = 30$  bietet für das RBS-Modul einen sinnvollen Kompromiss aus einer guten Sensitivität und einer geringen Verzögerung. Für eine gegebene Fehlalarmwahrscheinlichkeit  $\alpha$  lässt sich ein Schwellenwert  $h$  für  $g_{M,i}[k]$  auf Basis der Wahrscheinlichkeitsdichtefunktion  $\rho_{\chi_M^2}(x)$  der  $\chi_M^2$ -Verteilung gemäß

$$\int_h^\infty \rho_{\chi_M^2}(x) dx = \alpha \quad (5.308)$$

berechnen [17]. Die Eingrenzung des Fehlers erfolgt mit einer Fuzzifizierung des von Gustafsson vorgeschlagenen Diagnosealgorithmus [101]. Dazu vergleicht der Algorithmus, nach erfolgreicher Fehlererkennung, die Richtung des aktuellen Residuenvektors mit der Richtung des Vektors für jeden Fehlerfall. Der diagnostizierte Fehler ist der Fehler, der den Winkel zwischen seiner Richtung und dem aktuellen Residuum minimiert. Gustafsson isoliert den  $i$ -ten Fehler zum Zeitpunkt  $k$  durch  $\hat{i}[k] = \arg \min_i d_i[k]$  [101], mit

$$d_i[k] = \left\| \frac{\mathbf{r}[k]}{\|\mathbf{r}[k]\|} - \frac{\boldsymbol{\mu}_i}{\|\boldsymbol{\mu}_i\|} \right\|^2 = \sphericalangle(\mathbf{r}[k], \boldsymbol{\mu}_i). \quad (5.309)$$

$\boldsymbol{\mu}_i$  bezeichnet die Richtung, die der Residuenvektor einnehmen würde, falls der  $i$ -te Fehler aufgetreten ist. Die positiven und negativen Fehleramplituden müssen dabei getrennt behandelt werden, da der Richtungsvektor  $\boldsymbol{\mu}_i$  für das entgegengesetzte Vorzeichen in die entgegengesetzte Richtung weist [101]. Um eine Konfidenz für die jeweilige Entscheidung anzugeben, wird der Ansatz der Fehlerisolierung unscharf gefasst. Das Verfahren berechnet zu jedem Zeitschritt einen Zugehörigkeitsgrad  $u_i[k] \in [0, 1]$  mit  $\sum_{j=1}^C u_j[k] = 1$  für jeden Fehler auf der Grundlage des aktuellen Residuenvektors  $\mathbf{r}[k]$  [15, 200]:

$$u_i[k] = \begin{cases} \left( \frac{\sum_{j=1}^C \left( \frac{d_i[k]}{d_j[k]} \right)^{2/(l-1)}}{\sum_{j=1}^C \left( \frac{d_i[k]}{d_j[k]} \right)^{2/(l-1)}} \right)^{-1} & d_i[k] \neq 0 \\ 1 & d_i[k] = 0, \end{cases} \quad (5.310)$$


wobei  $l > 1$  und  $C$  die Gesamtzahl der Fehler ist. Diese Fuzzifizierung ermöglicht die Diagnose von Parameter- und Sensorfehlern in einem gemeinsamen Framework. Nach Sammeln von  $N$  Residuenwerten und der Annahme von Detektierbarkeit, lässt sich die Wahrscheinlichkeit für jeden Fehler, Hypothese  $\mathcal{H}_i \in \mathbb{H}$ , gemäß

$$P(\mathcal{H}_i | \Phi_s, \mathcal{H}_i \text{ detek.}) = \left( 1 - \tilde{P}(\mathcal{H}_0 | \Phi_s) \right) \frac{1}{N} \sum_{k=1}^N u_i[k] \quad (5.311)$$

berechnen. Dabei entspricht  $\tilde{P}(\mathcal{H}_0 | \Phi_s)$  der Wahrscheinlichkeit, dass kein Fehler vorliegt. Ähnlich der Notation in [135] ist  $\Phi_s$  der Beobachtungsraum während des Schaltzustands  $s$  und  $\mathbb{H}$  der Hypothesenraum, also die Menge aller Hypothesen. Der  $i$ -te Fehler muss strukturell detektierbar sein.

Die Berechnung der Fehlerwahrscheinlichkeit (5.311) erfordert die Kenntnis von  $\tilde{P}(\mathcal{H}_0 | \Phi_s)$ . Betrachtet man die quadrierte Norm eines Residuenvektors  $\|\mathbf{r}\|^2 = \|\mathbf{d} + \mathbf{f}\|^2$  zu jedem Zeitpunkt  $k$  mit dem Rauschvektor  $\mathbf{d} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$  und dem unbekanntem Einfluss des Fehlers  $\mathbf{f} \in \mathbb{R}^n$ , so ist die Norm  $\|\mathbf{r}\|^2$  entsprechend einer nicht zentrierten  $\chi_{n,\lambda}^2$ -Verteilung mit dem Verschiebungsparameter

$$\lambda = \sum_{i=1}^n f_i^2 \quad (5.312)$$



**Abbildung 5.11:** Verteilung der quadrierten Residuenvektornorm im fehlerfreien Fall (blau) und im fehlerhaften Fall (rot). Der grau markierte Bereich unter beiden Verteilungen gibt die Wahrscheinlichkeit an, dass kein Fehler vorliegt  $\tilde{P}(\mathcal{H}_0|\Phi_s)$ .

und  $n$  Freiheitsgraden verteilt. Der Erwartungswert von  $\|\mathbf{r}\|^2$  lässt sich gemäß

$$\begin{aligned}
 E[\|\mathbf{r}\|^2] &= E\left[\sum_{j=1}^n (d_j^2 + f_j^2 + 2d_j f_j)\right] \\
 &= \sum_{j=1}^n \left( \underbrace{E[d_j^2]}_{=1} + E[f_j^2] + 2 \underbrace{E[d_j f_j]}_{=0} \right) \\
 &= n + \sum_{j=1}^n f_j^2
 \end{aligned} \tag{5.313}$$

berechnen. Unter der Annahme eines konstanten Fehleranteils  $\mathbf{f}[k] \approx \text{const.}$  approximiert die Fläche zwischen der nicht zentrierten  $\chi_{n,\lambda}^2$  und der zentrierten  $\chi_n^2$ -Verteilung mit  $n$  Freiheitsgraden und  $\lambda = \frac{1}{k} \sum_{j=1}^k \|\mathbf{r}[j]\| - n$  die Wahrscheinlichkeit, dass kein Fehler vorliegt (siehe Abbildung 5.11):

$$\begin{aligned}
 \tilde{P}(\mathcal{H}_0|\Phi_s) &= \int_0^{\infty} \min(\rho_{\chi_n^2}(x), \rho_{\chi_{n,\lambda}^2}(x)) dx \\
 &= 1 - F_{\chi_n^2}(\hat{x}) + F_{\chi_{n,\lambda}^2}(\hat{x}).
 \end{aligned} \tag{5.314}$$

$\hat{x}$  bezeichnet, wie Abbildung 5.11 zeigt, den Schnittpunkt der zentrierten und der nicht zentrierten  $\chi_{n,\lambda}^2$ -Verteilung.

### 5.6.2 Detektierbarkeitsmaß

Voraussetzung für die Erklärung einer Hypothese ist die analytische Detektierbarkeit des Fehlers. Betrachtet man den Fall, dass die Fehler  $f_1$  und  $f_2$  nach der Entdeckung gleichwahrscheinlich sind. Angenommen, der Algorithmus wählt einen Schaltzustand, im Folgenden

Aktion  $a_j \in \mathbb{A}$  genannt, wobei  $f_1$  strukturell detektierbar ist,  $f_2$  jedoch nicht. Wenn die Residuen nach  $a_j$  ungefähr Null sind, könnte der Algorithmus fälschlicherweise zu dem Schluss kommen, dass der Fehler  $f_2$  vorhanden ist, da  $\mathbf{r} \approx 0$  auf ein fehlerfreies System hinweist. Dies kann jedoch die falsche Entscheidung sein, wenn  $f_1$  nach der Aktion  $a_j$  strukturell, aber nicht analytisch detektierbar ist.

Die Detektierbarkeit eines Fehlers wird mit der Empfindlichkeit von Residuen gegenüber dem Fehler und einer Schätzung der Fehleramplitude quantifiziert. Ist die Fehleramplitude nicht bekannt, so verwendet der Algorithmus die minimale detektierbare Fehleramplitude (siehe Abschnitt 5.7.1), was zu einer maximal konservativen Entscheidung führt. Im Diagnose-Framework aus Abbildung 5.10 wird die Fehleramplitude für jeden Fehler jedoch durch ein separates SPKF (analog zu Abschnitt 5.5.2) mit dem Fehlermodell  $f_i[k] = f_i[k-1] + \xi_{f_i}, \xi_{f_i} \sim \mathcal{N}(0, \sigma_{f_i}^2)$  geschätzt. Betrachtet man einen linearen Residuenvektor

$$\mathbf{r}[k] = \mathbf{H}_d[k]\mathbf{d} + \mathbf{H}_f[k]\mathbf{f} \quad (5.315)$$

mit den Störungen  $\mathbf{d}$  und den Fehlern  $\mathbf{f}$ , so folgt die Empfindlichkeit des Residuums gemäß [59]:

$$S_f = \|\mathbf{H}_f[k]\|. \quad (5.316)$$

Nach Ding stellt dies das Best-Case-Szenario für den Einfluss von  $\mathbf{f}$  dar [59]. Für Fehler, die die Residuen nicht linear beeinflussen, wie in Gleichung (5.315), approximiert die am Arbeitspunkt  $OP$  ausgewertete Ableitung die Empfindlichkeit:

$$S_f = \left\| \left. \frac{\delta \mathbf{r}[k]}{\delta \mathbf{f}} \right|_{OP} \right\|. \quad (5.317)$$

Auf dieser Grundlage liefert Definition 5.1 die Nachweisbarkeit  $\mathcal{D}_i$  für den Fehler  $f_i$  wie folgt:

**Definition 5.1** (Quantifizierung der Detektierbarkeit). Sei  $\mathbf{r}$  ein  $n$ -dimensionaler Residuenvektor,  $S_{f_i}$  die Empfindlichkeit von  $\mathbf{r}$  gegenüber dem  $i$ -ten Fehler und  $f_i$  die bekannte Fehleramplitude, dann quantifiziert

$$\begin{aligned} \mathcal{D}_i &= 1 - \int_0^\infty \min(\rho_{\chi_n^2}(x), \rho_{\chi_{n,\lambda}^2}(x)) dx \\ &= F_{\chi_n^2}(\hat{x}) - F_{\chi_{n,\lambda}^2}(\hat{x}) \end{aligned} \quad (5.318)$$

die Detektierbarkeit, mit  $\lambda = S_{f_i}^2 f_i^2$ . Dabei ist  $\rho_{\chi_n^2}(x)$  die Wahrscheinlichkeitsdichtefunktion der nicht-zentralen  $\chi^2$ -Verteilung mit  $n$  Freiheitsgraden und dem Offset  $\lambda$ ,  $F_{\chi_{n,\lambda}^2}(x)$  die zugehörige kumulative Verteilungsfunktion und  $\hat{x} \in \{x \in \mathbb{R} \mid \rho_{\chi_n^2}(x) = \rho_{\chi_{n,\lambda}^2}(x), \lambda = S_{f_i}^2 f_i^2\}$ , siehe Abbildung 5.11.

Die Quantifizierung der Detektierbarkeit verfolgt einen ähnlichen Ansatz wie die Berechnung

der Wahrscheinlichkeit für  $\mathcal{H}_0$ . Das durch Definition 5.1 gegebene Detektierbarkeitsmaß  $\mathcal{D}_i$  lässt sich als die Wahrscheinlichkeit  $P(\mathcal{H}_i \text{ detek.} | \Phi_s)$  betrachten, dass der Fehler  $f_i$  im aktuellen Messraum  $\Phi_s$  detektierbar ist. Unter der Annahme, dass der Fehler  $f_i$  nach der Aktion  $a_j$  nicht mehr detektierbar ist, entspricht die Hypothese  $\mathcal{H}_i$  der Hypothese  $\mathcal{H}_0$ . Um die Wahrscheinlichkeit für  $\mathcal{H}_i$  dennoch quantifizieren zu können, schlägt die Arbeit, basierend auf Gleichung (5.314), die folgende Formel vor:

$$P(\mathcal{H}_i | \Phi_s, \mathcal{H}_i \text{ nicht detek.}) = \frac{\hat{P}_i}{\sum_{j=0}^{|\mathbb{H}|} (1 - \mathcal{D}_j) \hat{P}_j} \tilde{P}(\mathcal{H}_0 | \Phi_s). \quad (5.319)$$

Dabei ist  $|\mathbb{H}|$  die Kardinalität der Hypothesenmenge. Gleichung (5.329) definiert  $\hat{P}_i$ . Unter Verwendung der Gleichungen (5.311), (5.318) und (5.319) ist damit die Wahrscheinlichkeit für jeden Fehler im Messraum  $\Phi_s$  gegeben als:

$$\begin{aligned} P(\mathcal{H}_i | \Phi_s) &= \mathcal{D}_i P(\mathcal{H}_i | \Phi_s, \mathcal{H}_i \text{ detek.}) \\ &+ (1 - \mathcal{D}_i) P(\mathcal{H}_i | \Phi_s, \mathcal{H}_i \text{ nicht detek.}). \end{aligned} \quad (5.320)$$

Zu beachten ist, dass  $P(\mathcal{H}_i | \Phi_0)$  für  $k = 0$ , nicht definiert ist. Per Definition muss jedoch der für die Erkennung verantwortliche Fehler für  $s = 0$  detektierbar sein, das heißt

$$P(\mathcal{H}_i | \Phi_0) = \begin{cases} P(\mathcal{H}_i | \Phi_0, \mathcal{H}_i \text{ detek.}) & i \neq 0, \mathcal{H}_i \text{ strukt. detek.} \\ \tilde{P}(\mathcal{H}_0 | \Phi_0) & i = 0 \\ 0 & \text{sonst.} \end{cases} \quad (5.321)$$

### 5.6.3 Aktive Fehlerisolation

Die Idee der aktiven Fehlerisolation in RBSs besteht darin, Schalter zu öffnen und zu schließen, um das Vertrauen in einen vorliegenden Fehler zu erhöhen und die Isolationsmöglichkeiten zu verbessern. Das Vertrauen in einen Fehler aktualisiert das Verfahren durch rekursive Bayes-Schätzung und das Bayes-Theorem [30, 204]:

$$\begin{aligned} P(\mathcal{H}_i | \Phi_{0:s}) &= \frac{P(\Phi_s | \mathcal{H}_i) P(\mathcal{H}_i | \Phi_{0:s-1})}{P(\Phi_s | \Phi_{0:s-1})} \\ &= \frac{P(\mathcal{H}_i | \Phi_s) P(\mathcal{H}_i) P(\mathcal{H}_i | \Phi_{0:s-1})}{P(\Phi_s) P(\Phi_s | \Phi_{0:s-1})}, \end{aligned} \quad (5.322)$$

mit

$$\Phi_{0:s} = \bigcap_{\zeta=0}^s \Phi_\zeta. \quad (5.323)$$

Anhang A.6 zeigt eine detaillierte Herleitung von Gleichung (5.322). Da

$$\sum_{i=1}^{|\mathbb{H}|} P(\mathcal{H}_i | \Phi_{0:s}) = 1, \forall s \quad (5.324)$$

gilt (*Closed-World-Annahme*), muss der Nenner nicht bekannt sein.  $P(\mathcal{H}_i | \Phi_s)$  berechnet sich gemäß den Gleichungen (5.320) und (5.321). Bei  $P(\mathcal{H}_i)$  handelt es sich um einen Wert, der vorab festgelegt werden muss. Nach Isermann sollte die Bedeutung der Vorwerte in diesem Zusammenhang nicht unterschätzt werden [127]. Eine sorgfältige Wahl dieser Werte verbessert die Leistung der Fehlerdiagnose. Wenn jedoch keine Kenntnisse über  $P(\mathcal{H}_i)$  vorhanden sind, werden sie üblicherweise auf  $P(\mathcal{H}_i) = 1/|\mathbb{H}|$  gesetzt. Diese Wahl trifft auch die vorliegende Arbeit, was zu sehr guten Isolationsergebnissen führt, wie Abschnitt 5.7.2 zeigt.

Im nächsten Schritt soll eine Vorschrift zur Wahl der nächsten Aktion  $a_j[s+1]$  eingeführt werden. Die Variable  $J$  bezeichnet dabei die Anzahl aller möglichen Aktionen. Da sequentielle und adaptive Tests nicht-sequentielle und nicht-adaptive Lösungen übertreffen, wird ein adaptiver, sequentieller Ansatz gewählt [205]. Das Ziel des aktiven, sequentiellen Hypothesentests ist es, sensorische Aktionen

$$\mathbf{A}_{0:S} = \bigcap_{s=0}^S a_j[s], \quad (5.325)$$

einen Stoppzustand  $S$  und eine Deklarationsregel  $d : \Phi_{0:S} \times \mathbf{A}_{0:S} \rightarrow \mathbb{H}$  zu finden, die die erwarteten Gesamtkosten minimieren. Der Beobachtungsraum  $\Phi_s$  kann dabei aus Residuen oder Messungen bestehen. Die erwarteten Gesamtkosten  $\gamma_{\text{ETC}}$  lassen sich als

$$\gamma_{\text{ETC}} = E[S] + LP_e \quad (5.326)$$

schreiben, mit den Kosten  $L$  für die Abgabe einer falschen Erklärung.

$$P_e = P(d(\Phi_{0:S-1}, \mathbf{A}_{0:S-1}) \neq \mathcal{H}_i) \quad (5.327)$$

bezeichnet die Wahrscheinlichkeit, die falsche Deklaration zu machen, das heißt  $\mathcal{H}_i$  nicht zu deklarieren, obwohl  $\mathcal{H}_i$  wahr ist.  $E[S]$  ist die erwartete Anzahl von Aktionen, die erfolgen müssen, bis  $\mathcal{H}_i$  akzeptiert wird.  $a_j[s+1]$  bezeichnet eine mögliche nächste Aktion nach  $a_j[s]$ . Die Arbeit passt die zweite Vorschrift  $\pi_2$  von Naghshvar und Javidi so an, dass sie unabhängig von der Schätzung der Fehleramplitude ist [203]. Die Anpassung erhöht die Robustheit gegenüber einer falschen Fehleramplitudenschätzung. Die Vorschrift wählt aus  $J$  möglichen Aktionen die nächste Aktion  $a_j[s+1]$  aus, die gemäß den Hypothesen den höchsten Informationsgewinn verspricht. Naghshvar und Javidi vergleichen dazu den Kernel  $\rho_i^{(a_j[s+1])}$  für die Hypothese  $\mathcal{H}_i = \text{wahr}$  nach der Aktion  $a_j[s+1]$  mit der erwarteten Wahrscheinlichkeitsdichtefunktion

$\bar{\rho}_i^{(a_j[s+1])}$  der Residuen für  $\mathcal{H}_i = \textit{falsch}$  [203]. Dazu berechnen die Autoren  $\bar{\rho}_i^{(a_j[s+1])}$  gemäß

$$\bar{\rho}_i^{(a_j[s+1])} = \sum_{j \neq i} \frac{\hat{P}_j}{1 - \hat{P}_i} \rho_j^{(a_j[s+1])}, \quad (5.328)$$

mit

$$\hat{P}_i := P(\mathcal{H}_i | \Phi_{0:s}). \quad (5.329)$$

Im Gegensatz dazu vergleicht der Ansatz der vorliegenden Arbeit die Residuenrichtung  $\boldsymbol{\mu}_i^{(a_j[s+1])}$  für jede mögliche nächste Aktion  $a_j[s+1]$  für den Fall  $\mathcal{H}_i = \textit{wahr}$  mit dem Residuenvektor  $\bar{\boldsymbol{\mu}}_i^{(a_j[s+1])}$  für den Fall  $\mathcal{H}_i = \textit{falsch}$ . Hierbei wird definiert, dass, wenn der  $i$ -te Fehler (Hypothese  $\mathcal{H}_i$ ) nach der Aktion  $a_j[s+1]$  strukturell nicht detektierbar ist, der Residuenvektor  $\boldsymbol{\mu}_i^{(a_j[s+1])}$  den Wert  $\boldsymbol{\mu}_i^{(a_j[s+1])} = \mathbf{0}$  annimmt. Wenn  $\mathcal{H}_i$  strukturell detektierbar ist, dann normiert der Ansatz den Vektor  $\boldsymbol{\mu}_i^{(a_j[s+1])}$  so, dass  $\|\boldsymbol{\mu}_i^{(a_j[s+1])}\| = 1$  gilt. Je größer die Differenz zwischen diesen beiden Vektoren ist, desto besser ist die erwartete Unterscheidbarkeit von  $\mathcal{H}_i = \textit{wahr}$  zu  $\mathcal{H}_i = \textit{falsch}$ . Um die Vorschrift formal zu beschreiben, wird die Matrix  $\mathbf{\Lambda} \in \mathbb{R}^{|\mathbb{H}| \times J}$  eingeführt. Die Elemente von  $\mathbf{\Lambda}$  sind gemäß

$$\mathbf{\Lambda}_{(i,j)} = \lambda_{a_j} \left\| \boldsymbol{\mu}_i^{(a_j)} - \bar{\boldsymbol{\mu}}_i^{(a_j)} \right\|, \quad (5.330)$$

mit

$$\bar{\boldsymbol{\mu}}_i^{(a)} = \sum_{j \neq i} \frac{\hat{P}_j}{1 - \hat{P}_i} \boldsymbol{\mu}_j^{(a)}, \quad (5.331)$$

gegeben. Die daraus resultierende Vorschrift lautet wie folgt:


1.  $\hat{P}_i < \tilde{p}$ : Wähle  $a_j$  als  $\arg \max_{a_j \in \mathbb{A}} \min_{\mathcal{H}_i \in \mathbb{H}} \mathbf{\Lambda}$ .
2.  $\exists \hat{P}_i \in [\tilde{p}, 1 - L^{-1}]$ : Wähle  $a_j$  als  $\arg \max_{a_j \in \mathbb{A}} \mathbf{\Lambda}_{(i,1:J)}$ .
3.  $\exists \hat{P}_i \geq 1 - L^{-1}$ : Akzeptiere  $\mathcal{H}_i$ .

Die Variable  $\lambda_{a_j}$  ist ein Einstellparameter, um bestimmte Aktionen gegenüber anderen zu bevorzugen. Für die vorliegende Anwendung sind alle Aktionen gleichberechtigt, weshalb  $\lambda_{a_j} = \frac{1}{|\mathbb{A}|} \forall a_j$  gewählt wird. Auch der Schwellwert  $\tilde{p} > 0.5$  ist ein Einstellparameter, der auf  $\tilde{p} = 0.75$  gesetzt wird.

Das nachfolgende Beispiel 5.2 demonstriert die Anwendung der aktiven Fehlerisolation.

**Beispiel 5.2.** Wie Abbildung 5.12 zeigt, sollen vier Hypothesen ( $|\mathbb{H}| = 4$ ) in einem zwei-dimensionalen Residuenraum  $\mathbf{r} \in \mathbb{R}^2$  betrachtet werden. Die Wahrscheinlichkeiten für die jeweiligen Hypothesen betragen  $\hat{P}_1 = 0.4$ ,  $\hat{P}_2 = 0.3$ ,  $\hat{P}_3 = 0.2$  und  $\hat{P}_4 = 0.1$ . Darüber hinaus zeigt Abbildung 5.12 die Residuenvektoren  $\boldsymbol{\mu}_i^{(a_j[s+1])}$  für die Aktion  $a_1[s+1]$  und  $a_2[s+1]$ .  $f_2$  ist in der Aktion  $a_2[s+1]$  strukturell nicht detektierbar, weshalb nach Definition  $\boldsymbol{\mu}_2^{(a_2[s+1])} = \mathbf{0}$





**Abbildung 5.12:** Abbildungen zum Beispiel 5.2: Richtung der Residuenvektoren für jeden Fehler nach der Aktion  $a_1[s+1]$  und nach der Aktion  $a_2[s+1]$ , mit  $\mu_1 : \hat{P}_1 = 0.4$ ,  $\mu_2 : \hat{P}_2 = 0.3$ ,  $\mu_3 : \hat{P}_3 = 0.2$ ,  $\mu_4 : \hat{P}_4 = 0.1$ .


folgt. Die Vektoren  $\bar{\mu}_1^{(a_j[s+1])}$  für  $j = \{1, 2\}$  sind als gestrichelte Linie dargestellt. Das Beispiel zeigt, dass sich der Fall  $\mathcal{H}_1 = \text{wahr}$  nach der Aktion  $a_2[s+1]$  deutlich besser vom Fall  $\mathcal{H}_1 = \text{falsch}$  unterscheiden lässt, als vor der Aktion  $a_1[s+1]$ .

## 5.7 Anwendung auf das Batteriesystem

Zur Validierung des im vorangegangenen Abschnitt 5.6 vorgestellten Verfahrens zur aktiven Fehlerdiagnose wendet der vorliegende Abschnitt die Methoden auf das RBS-Modul an. Dafür untersucht Abschnitt 5.7.1 zunächst das Isolationsvermögen des aktiven Ansatzes gegenüber der passiven Fehlerdiagnose, bevor die minimal detektierbaren Amplituden zu jedem der Fehler ermittelt werden. Abschnitt 5.7.2 stellt anhand eines fehlerfreien Tests den Lernprozess des beschränkten SPKFs vor, das die Modellparameter, basierend auf dem in Abschnitt 5.4.2 vorgestellten Versuchsaufbau, korrigiert. Die Vorteile der aktiven Fehlerisolation gegenüber der konventionellen Diagnose zeigen die Abschnitte 5.7.3 und 5.7.4 anhand zweier exemplarischer Fehler, die der Versuchsaufbau experimentell emuliert.

### 5.7.1 Simulative Ergebnisse

Mithilfe des elektrischen Modells des RBS-Moduls aus Abschnitt 5.2 untersucht dieser Abschnitt das Isolationsvermögen des aktiven Ansatzes gegenüber der konventionellen, passiven Fehlerdiagnose. Dazu regt das in Abbildung 5.13 gezeigte Stromprofil, basierend auf dem WLTP-Fahrzyklus, das RBS-Modul dynamisch an. Die aktive Fehlerdiagnose basiert auf




**Abbildung 5.13:** WLTP-basiertes Stromprofil.

**Tabelle 5.5:** Für die Simulationen und die experimentelle Validierung verwendete Rauschwerte.

$\sigma_{v_{\text{cell},i}}^2$	$\sigma_{i_{\text{cell},i}}^2$	$\sigma_{v_{\text{total}}}^2$	$\sigma_{i_{\text{total}}}^2$
$1 \cdot 10^{-8}$	$5.8 \cdot 10^{-6}$	$2.6 \cdot 10^{-6}$	$4 \cdot 10^{-4}$

den in Abschnitt 5.5 vorgestellten Residuen und dem beschränkten SPKF sowie dem in Abschnitt 5.6.3 vorgestelltem aktiven Verfahren. Tabelle 5.5 liefert die für die Simulation und die experimentelle Validierung (Abschnitt 5.7.2) verwendeten Rauschwerte, die für die Sensoren des Versuchsaufbaus aus Abbildung 5.7 vorab ermittelt wurden. Zunächst wird das Detektions- und Isolationsvermögen des Diagnosesystems für jeden Fehler aus Abbildung 5.2 ermittelt. Dafür erfolgt ein Test mit hoher Fehleramplitude. Diese beträgt bei den Sensorfehlern  $\pm 1$  V und  $\pm 1$  A. Fehler in  $R_{\text{con}}$ ,  $R_{\text{act,on}}$  und  $R_o$  besitzen einen Widerstand von  $70 \text{ m}\Omega$ . Der Widerstand fehlerhafter Stromschienen  $R_{\text{bn}}$ ,  $R_{\text{bp}}$  erhöht sich um  $10 \text{ m}\Omega$ . Für einen Fehler im geöffnetem BS nimmt der Test an, dass sich dessen Widerstand auf  $3.3 \Omega$  reduziert. Fehler von  $E_m$  werden durch einen Spannungsabfall von  $10 \%$  modelliert.

Abbildung 5.14 zeigt die resultierende Isolierbarkeitsmatrix. Die auf der Abszisse gezeigten Fehler lassen sich isolieren, wenn die Fehler auf der Ordinate im System vorhanden sind. Die Isolationsfähigkeit der passiven Fehlerdiagnose zeigen schwarze Quadrate. Die zusätzliche Fehlerisolation durch die aktive Fehlerdiagnose ergänzt eine graue Markierung. Wie Abbildung 5.14 zeigt, ist die Isolierbarkeit von Fehlern im Allgemeinen nicht unbedingt eine symmetrische Eigenschaft [135]. Im Falle der aktiven Fehlerdiagnose resultiert die Asymmetrie aufgrund von Wissen über das Vorzeichen des Fehlers, das der in Abschnitt 5.6.1 beschriebene Isolationsalgorithmus einbringt. Auf diese Weise ist ein Fehler im Gesamtspannungssensor  $v_{\text{total}}$  von einem Fehler auf den Stromschienen zwischen den einzelnen Zellreihen isolierbar. Die zusätzliche Isolierbarkeit erreicht das Verfahren durch die Annahme, dass der Widerstand auf den Stromschienen nur zunehmen und nicht abnehmen kann. In ähnlicher Weise sind die Fehler  $f_{R_o,i}$  von den Fehlern  $f_{E_m,i}$  isolierbar, aber nicht umgekehrt. Die verbesserte Isolierbarkeit erreicht der Ansatz mit der Annahme, dass  $E_{m,i}$  nur abnehmen kann, während



**Abbildung 5.14:** Fehler-Isolierbarkeitsmatrix des 2s3p-Batteriemoduls. Vergleich von passiver und aktiver Fehlerdiagnose, einschließlich Systemwissen. Die Bezeichnungen der Ordinate (eingefügter Fehler) und der Abszisse (diagnostizierter Fehler) sind identisch. Zur besseren Lesbarkeit sind die Fehler jeweils auf zwei Achsen dargestellt und die Fehler der Ordinate durch Mengen und  $i \in [1, 6]$  zusammengefasst.

$R_{o,i}$  zu- und abnehmen kann. Die aktive Fehlerisolation ermöglicht zudem eine erweiterte Isolation für Fehler in den Kontaktwiderständen und Fehler in den ASs. Darüber hinaus verbessert sich die Isolationsfähigkeit für die Fehler  $f_{E_m,i}$  und  $f_{R_{o,i}}$ . Beide Fehler lassen sich durch die aktive Fehlerdiagnose symmetrisch isolieren.

Um die minimal detektierbare Amplitude für jeden Fehler zu ermitteln, erhöht der Test die Fehleramplitude kontinuierlich, bis der Algorithmus den Fehler detektiert. Tabelle 5.6 zeigt das die resultierenden Amplituden für alle Sensoren und Parameter im vorliegenden System aus

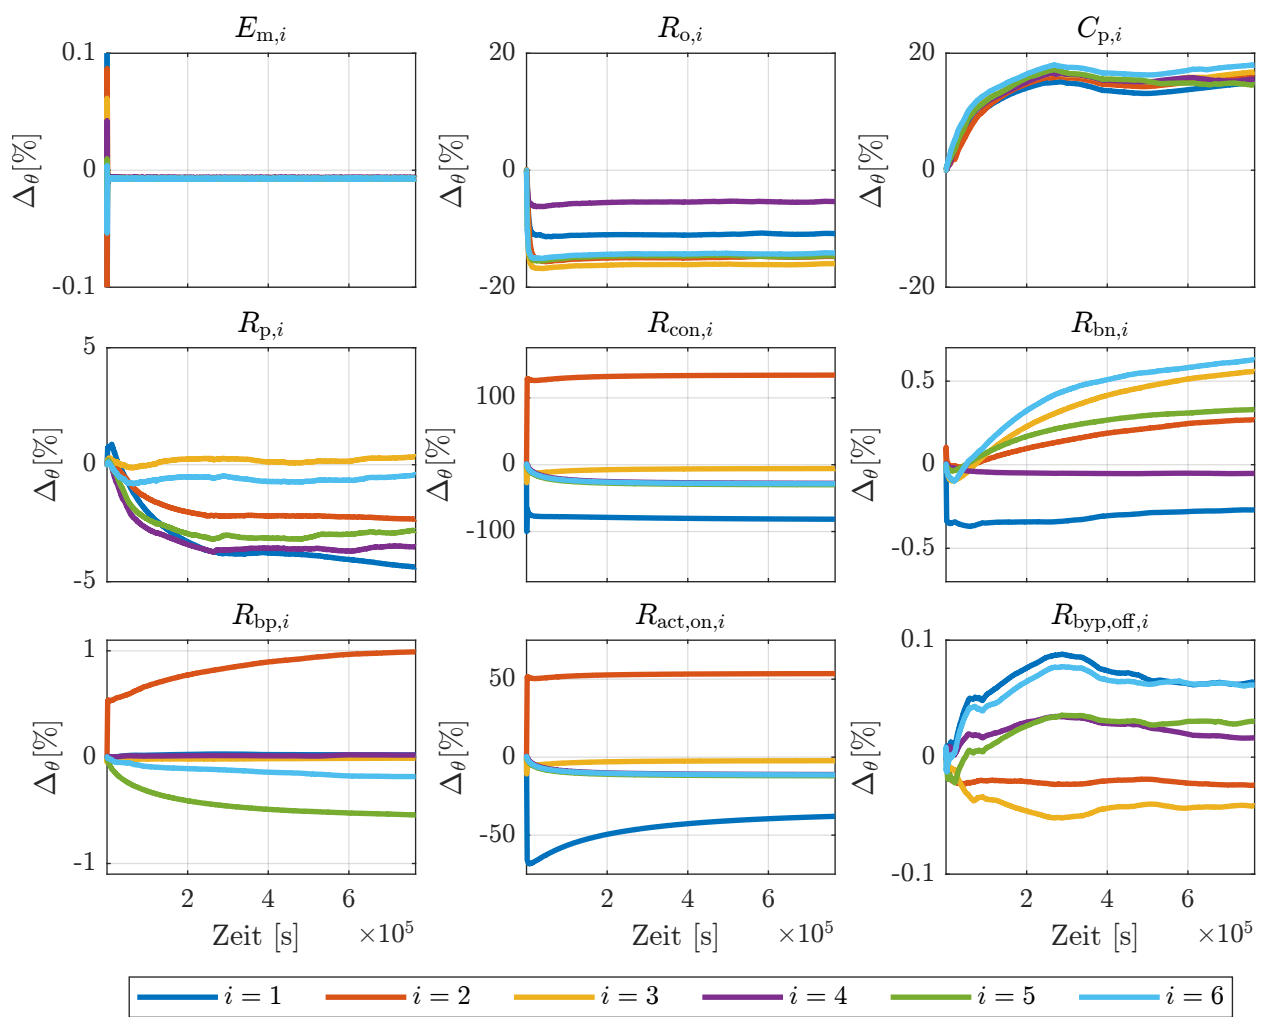

**Tabelle 5.6:** Minimal detektierbare Fehleramplitude für jeden Fehler.

Index $i =$	1	2	3	4	5	6
$i_{\text{cell},i}$ [mA]	14	15	14	15	16	15
$v_{\text{cell},i}$ [mV]	0.4	0.3	0.4	0.3	0.2	0.4
$E_{\text{m},i}$ [mV]	0.8	1.6	1.6	1.2	0.8	1.6
$R_{\text{o},i}$ [m $\Omega$ ]	3.1	3.6	4.1	2	2	3.6
$R_{\text{con},i}$ [m $\Omega$ ]	0.2	0.16	0.24	0.12	0.24	0.2
$R_{\text{bn},i}$ [m $\Omega$ ]	0.17	0.08	0.53	0.13	0.13	0.53
$R_{\text{bp},i}$ [m $\Omega$ ]	0.53	0.08	0.24	0.53	0.1	0.2
$R_{\text{act,on},i}$ [m $\Omega$ ]	0.2	0.16	0.24	0.12	0.24	0.2
$R_{\text{byp,off},i}$ [ $\Omega$ ]	260	260	260	340	320	320
$i_{\text{total}} : 12 \text{ mA}, v_{\text{total}} : 4.6 \text{ mV}$						

Abbildung 5.7. Hat der Algorithmus den Fehler innerhalb von 400 Iterationen ( $\Delta t = 0.96 \text{ s}$ ) erkannt, gilt der Fehler als detektiert, ansonsten erhöht sich die Amplitude. Die Sensoren besitzen die in Tabelle 5.5 gezeigten Rausch-Level. Der Wert von  $R_{\text{byp,off},i}$  ist der Wert, auf den der Widerstand des Schalters abfallen muss, um nachweisbar zu sein. Die minimal detektierbaren Fehleramplituden variieren leicht zwischen den Zellen. Ein Grund dafür ist die unterschiedliche Empfindlichkeit der implementierten Residuen gegenüber dem jeweiligen Fehler. Ein zusätzlicher Faktor sind die Parametervariationen der Zell- und Systemparameter. Aufgrund des relativ hohen Rausch-Levels des Gesamtstromsensors lassen sich Fehler, die die Stromsensoren betreffen, erst ab Amplituden von einigen Milliampere detektieren. Die Erkennbarkeit eines Zellparameterfehlers ( $R_{\text{o},i}$ ,  $E_{\text{m},i}$ ) hängt zudem von der Abtastrate des Algorithmus ab, die hier jedoch konstant  $\Delta t = 0.96 \text{ s}$  beträgt. Die Detektierbarkeit ist unabhängig vom Vorzeichen.

### 5.7.2 Fehlerfreier Fall

Die experimentelle Validierung des aktiven Fehlerdiagnose-Frameworks aus Abbildung 5.10 erfolgt an dem in Abschnitt 5.4.2 vorgestellten Versuchsaufbau. Basierend auf den implementierten Residuen passt der beschränkte Parameterschätzer die Modellparameter an das reale System an und schätzt die Fehleramplitude. Da die Parameter unterschiedliche Lernraten besitzen, werden die ersten, fehlerfreien 8 min jedes Tests wiederholt, bis die Residuen  $\tilde{g}_M$  unter der Fehlererkennungsschwelle  $h = 100$  liegen. Die Entwicklung der Residuen  $\tilde{g}_M$  während der Lernphase zeigt Abbildung 5.15a. Ausgehend von einer Amplitude  $|g_{M,i}| > 1000$  nehmen alle Residuen auf eine Amplitude  $g_{M,i} < h \forall i$  ab. Aus der Entwicklung der Residuen  $\tilde{g}_M$  ist ersichtlich, dass die geschätzten Parameter das System signifikant besser beschreiben als die anfangs verwendeten Durchschnittswerte. Abbildung 5.15b ergänzt die prozentuale Veränderung  $\Delta_\theta = 100 \cdot (\hat{\theta}_{k,j} - \hat{\theta}_{0,j}) / \hat{\theta}_{0,j}$  der zugehörigen Systemparameter. Die Anfangspa-




**Abbildung 5.15:** Experimentelle Ergebnisse des beschränkten Parameter-Schätzers: (a) Entwicklung der Residuen  $\tilde{g}_M$  während der Lernphase; (b) Prozentuale Änderung der Parameter während der Lernphase im Verhältnis zu den Anfangsparametern von Tabelle 5.7.

**Tabelle 5.7:** Initiale Parameter zu Beginn des Lernprozesses.

	$E_{m,i}[0]$ [V]	$R_{o,i}[0]$ [m $\Omega$ ]	$C_{p,i}[0]$ [F]	$R_{p,i}[0]$ [m $\Omega$ ]
$i = 1$	3.981	38.6	760	18.1
$i = 2$	3.981	38.6	902	20.8
$i = 3$	3.981	38.6	904	20.7
$i = 4$	3.982	38.7	887	21.1
$i = 5$	3.982	38.7	880	21.0
$i = 6$	3.982	38.7	918	20.3
	$R_{con,i}[0]$	$R_{\{bp,bn\},i}[0]$	$R_{act,on,i}[0]$	$R_{byp,off,i}[0]$
$i \in [1, 6]$	5 m $\Omega$	10 $\mu\Omega$	2 m $\Omega$	1 G $\Omega$

parameter liefert Tabelle 5.7. Die Ruhespannung  $E_{m,i}$  bleibt, mit Ausnahme einiger Peaks zu Beginn des Lernprozesses, nahezu unverändert. Das liegt daran, dass der SOC zu Beginn auf Basis der Leerlaufspannung eingestellt wurde (die Zellen waren vor Beginn der Messung in Ruhe). Die Entwicklung der Systemparameter während des Lernprozesses zeigt, dass das SPKF die Zellwiderstände ( $R_{o,i}$ ,  $R_{p,i}$ ) des Versuchsaufbaus im Vergleich zu den Anfangsparametern kleiner schätzt. Dies liegt daran, dass bei der Charakterisierung der Zellen nicht zwischen Zellwiderstand und Kontaktierung unterschieden wurde. Der Zellwiderstand ist daher etwa  $2 \cdot R_{con,i}$  zu hoch initialisiert, was der Parameterschätzer für den Versuchsaufbau korrigiert. Bereits im fehlerfreien Fall ist ein hoher Wert für den Kontaktwiderstand  $R_{con,2}$  zu beobachten. Um einen künstlichen, fehlerhaften Kontaktwiderstand einfügen zu können (siehe Abschnitt 5.7.4), muss der Schraubkontakt zwischen Zelle und Stromschiene modifiziert werden. Dadurch entsteht ein zusätzlicher Kontaktwiderstand in der Größenordnung von  $R_{con,2}$  (oberhalb von  $f_{R_{con,2}}$  in Abbildung 5.18). Dementsprechend schätzt das SPKF den anfänglichen, mittleren Kontaktwiderstand des fehlerfreien Systems auf etwa  $2 \cdot R_{con,2}$ , was einem zusätzlichen Widerstand von 7 m $\Omega$  entspricht. Dies wirkt sich auch auf die Schätzung des Widerstandes  $R_{act,on,2}$  (etwa 1 m $\Omega$  höher) aus, da er bei geöffnetem Bypass-Schalter in Serie zum Kontakt liegt und nicht vom Spannungssensor gemessen wird (Spannungsmessung  $v_{cell}$  in Abbildung 5.1). Die Stromschiene Widerstände  $R_{bn,i}$  und  $R_{bp,i}$  und der Widerstand  $R_{byp,off,i}$  unterscheiden sich um weniger als 1 % von ihren Anfangswerten. Je besser die Parameter des Residuengenerators an das Batteriesystem angepasst sind, desto geringer lässt sich das Prozessrauschen wählen. Ein höheres Prozessrauschen reduziert die Sensitivität der Methode.




**Abbildung 5.16:** Ersatzschaltbild der zweiten Reihe des Versuchsaufbaus aus Abbildung 5.7: Der interne Kurzschluss der Zelle  $i = 6$  wird durch Hinzufügen eines Widerstandes  $R_{ISC}$  emuliert.

### 5.7.3 Interner Kurzschluss

Laut der strukturellen Analyse nach Krysander, Aslund und Nyberg, lassen sich Fehler innerhalb der Zelle mit der vorhandenen Sensormenge nicht isolieren (siehe Abschnitt 5.3.1) [152]. Abbildung 5.14 zeigt, dass durch Hinzufügen von Systemwissen  $R_{o,i}$  von  $E_{m,i}$  isolierbar ist. Es ist mittels passiver Fehlerdiagnose jedoch nicht möglich,  $E_{m,i}$  von  $R_{o,i}$ , selbst nach Hinzufügen von Systemwissen, zu isolieren. Um die Vorteile einer aktiven Fehlerdiagnose zu zeigen, wird daher der Fehler  $f_{E_{m,6}}$  emuliert. Da der Versuchsaufbau in Abbildung 5.7 keinen Zugriff auf interne Zellvariablen bietet, wird der Fehler  $f_{E_{m,6}}$  durch Emulation eines internen Kurzschlusses eingebracht. Abbildung 5.16 zeigt hierzu die zweite Zellreihe des Testaufbaus. Die erste Reihe enthält keinen Fehler. In der zweiten Reihe ist ein Widerstand  $R_{ISC,6} = 3.37 \Omega$  parallel zu Zelle  $i = 6$  geschaltet. Aus der Sensorperspektive außerhalb der Zelle bewirkt der Widerstand einen sofortigen Abfall der Zellparameter  $E_{m,6}$ ,  $R_{o,6}$  und des Zustands  $v_{p,6}$  um den Faktor

$$c_f = \frac{R_{ISC,6}}{R_{ISC,6} + R_{o,6}} \approx 0.989. \quad (5.332)$$

Streng genommen widerspricht ein auf diese Weise nachgebildeter interner Kurzschluss der *Single-Fault*-Annahme. Allerdings nimmt der interne Widerstand, wie in Abschnitt 2.3.1 beschrieben, lediglich um etwa  $f_{R_{o,6}} \approx -0.39 \text{ m}\Omega$  ab. Somit liegt seine Änderung deutlich unter der minimal nachweisbaren Fehleramplitude, die Tabelle 5.6 zeigt. Änderungen im Zustand  $v_{p,6}$  äußern sich als Zellspannungsschwankungen und lassen sich daher durch Schwankungen in  $E_{m,6}$  abbilden. Da Fehler im RC-Glied der Zelle im Rahmen der aktiven Fehlerdiagnose nicht berücksichtigt werden, verursacht folglich der emulierte Fehler eine Änderung des Parameters  $E_{m,6}$ , wodurch der gewünschte Fehler repliziert wird. Die Änderung in  $E_{m,6}$  beträgt etwa  $f_{E_{m,6}} \approx -38.4 \text{ mV}$ .



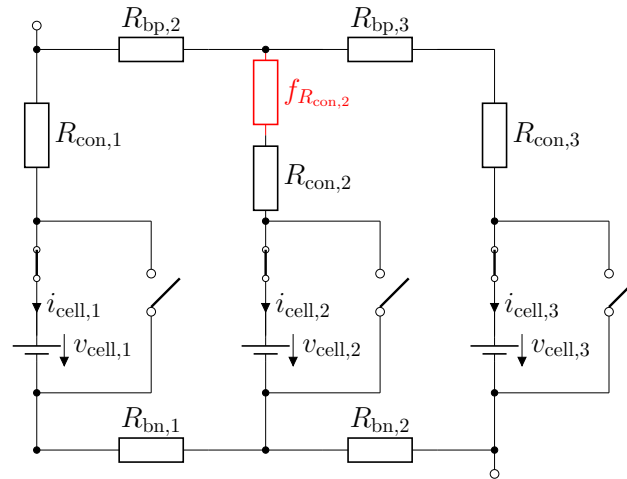
**Abbildung 5.17:** Experimentelle Ergebnisse für die Diagnose von  $f_{E_{m,6}}$ . Von oben nach unten: Schaltzustände für die zweite Reihe von RBS-Zellen, Wahrscheinlichkeit für die beiden wahrscheinlichsten Fehler, normierte geschätzte Fehleramplitude  $f_i$ , gemessene Zellströme  $i_{\text{Zelle},i}$ , gemessene Zellspannungen  $v_{\text{Zelle},i}$ , Wert der Residuen  $r$ .



Abbildung 5.17 zeigt die Ergebnisse bei Anwendung des aktiven Fehlerdiagnose-Frameworks. Die Schaltzustände für die zweite Zellreihe zeigt Abbildung 5.17 oben, gefolgt von den Wahrscheinlichkeiten für die beiden wahrscheinlichsten Fehler, der normierten geschätzten Fehleramplitude, den gemessenen Zellströmen  $i_{\text{cell},i}$  und Spannungen  $v_{\text{cell},i}$  sowie dem Wert der Residuen. Der Fehler tritt bei  $t = 610.8$  s auf und wird vom Verfahren bei  $t = 612$  s detektiert. Ein Sprung in den Zellströmen  $i_{\text{cell},i}$  und Zellspannungen  $v_{\text{cell},i}$  zeigt das Einbringen des Fehlers an. Vor dem Schalten beträgt die Wahrscheinlichkeit für die beiden Fehler  $f_{E_{m,6}}$  und  $f_{R_{o,6}}$  jeweils 50 %. Wenn also alle Zellen aktiv sind ( $s = 0$  von  $t = 0$  s bis  $t = 849.8$  s), ist der Fehler  $f_{E_{m,6}}$  vom Fehler  $f_{R_{o,6}}$  nicht isolierbar, wie es auch die Simulationen vorhergesagt haben (siehe Abbildung 5.14). Bei  $t = 849.8$  s schlägt der Algorithmus einen neuen Schaltzustand vor, die Aktion  $a_j[1]$ . Das aktive Testverfahren entscheidet, die Zelle  $i = 6$  aus dem System zu nehmen, um zwischen beiden Fehlern zu isolieren. Nachdem alle Zellen in der zweiten Reihe  $i \in \{4, 5, 6\}$  im *Bypass*-Zustand sind, sind die jeweiligen Zellströme  $i_{\text{cell},4,5,6} = 0$  und der Fehler  $f_{R_{o,6}}$  nicht beobachtbar. Die Zellspannungen nehmen jedoch, aufgrund des internen Kurzschlusses der Zelle  $i = 6$ , weiter ab. In den Residuen  $\mathbf{r}$  lässt sich beobachten, dass das System immer noch fehlerhaft ist. Somit bleibt nur der Fehler  $f_{E_{m,6}}$  als Möglichkeit. Folglich erhöht sich die Wahrscheinlichkeit für den Fehler  $f_{E_{m,6}}$  auf  $P(\mathcal{H}_{E_m} \mid \Phi_{0:1}) = 100$  %. Bei  $t = 1061$  s schaltet das System wieder in den Ausgangszustand, wobei alle Zellen außer Zelle  $i = 6$  im *Active*-Zustand sind. Die Ergebnisse zeigen am Beispiel des Fehlers  $f_{E_{m,6}}$ , dass sich die Isolationsfähigkeit durch aktive Fehlerdiagnose mittels Schalter erhöhen lässt.

#### 5.7.4 Erhöhter Kontaktwiderstand

Betrachtet man Abbildung 5.14, so ist ein weiterer wichtiger Fall für die Validierung der aktiven Fehlerdiagnose ein Fehler in einem Kontaktwiderstand  $f_{R_{\text{con},i}}$  oder dem AS  $f_{R_{\text{act,on},i}}$ . Deshalb untersucht der Abschnitt den Fehler  $f_{R_{\text{con},2}}$ , der den Kontakt der Zelle  $i = 2$  zur Stromschiene betrifft, indem der in Abbildung 5.18 gezeigte Widerstand auf  $f_{R_{\text{con},2}} = 71.9$  m $\Omega$  gesetzt wird. Abbildung 5.19 zeigt die Ergebnisse der aktiven Fehlerdiagnose für den erhöhten Kontaktwiderstand. Die Abbildung ist analog zu Abbildung 5.17 aufgebaut. Den bei  $t = 617.9$  s eingefügten Fehler erkennt der Algorithmus bei 618 s. Das Hinzufügen des Fehlers ist durch einen Sprung in den Zellströmen  $i_{\text{cell},i}$  und Zellspannungen  $v_{\text{cell},i}$  zu beobachten. Bis zum Zeitpunkt  $t = 862.5$  s befinden sich alle Zellen des Systems im *Active*-Zustand. Die Wahrscheinlichkeiten für einen Fehler in  $R_{\text{con},2}$  und  $R_{\text{act,on},2}$  liegen beide bei 46.8 %. Die Wahrscheinlichkeiten für alle anderen Fehler liegen einzeln unter 1 % und summieren sich auf die verbleibenden 6.4 %. Bei  $t = 862.5$  s entscheidet das aktive Fehlerdiagnose-Verfahren, die Zelle  $i = 2$  in den *Bypass*-Zustand zu setzen und öffnet die ASs und BSs für die Zellen  $i \in \{1, 3\}$ , damit die beiden Fehler isolierbar sind. Nach dem Umschalten weichen die Residuen weiterhin von Null ab, wie Abbildung 5.19,  $\mathbf{r}$  zeigt. Ein Fehler in  $R_{\text{act,on},2}$  wäre jedoch mit dem aktuellen Schaltzustand nicht beobachtbar. Daher steigt die Wahrscheinlichkeit eines




**Abbildung 5.18:** Ersatzschaltbild der ersten Reihe des Versuchsaufbaus aus Abbildung 5.7: Der erhöhte Kontaktwiderstand bei Zelle  $i = 2$  wird durch einen zusätzlichen Widerstand  $f_{R_{con,2}}$  emuliert.


Fehlers in  $R_{con,2}$  auf  $P(\mathcal{H}_{R_{con,2}} \mid \Phi_{0:1}) = 99.85 \%$ .

Darüber hinaus eignet sich der experimentelle Test auch zur Validierung des Detektierbarkeitsmaßes. Bei  $t = 1065$  s schaltet der Algorithmus alle Zellen der ersten Zeile in den Zustand *Bypass*, sodass der Fehler  $f_{R_{con,2}}$  nicht mehr beobachtbar ist. Unter Hinzunahme des Detektierbarkeitsmaßes nach Definition 5.1 ist dies ein erwartetes Verhalten für einen Fehler in  $R_{con,2}$ . Daher steigt die Wahrscheinlichkeit für  $f_{R_{con,2}}$  auf  $P(\mathcal{H}_{R_{con,2}} \mid \Phi_{0:2}) = 100 \%$ . Ohne das Detektierbarkeitsmaß würde der Algorithmus den Fehler immer noch als detektierbar betrachten. In Folge könnte die Fehlerwahrscheinlichkeit von  $f_{R_{con,2}}$  sinken.

Um das Detektierbarkeitsmaß weiter zu validieren, schaltet ein weiterer Test alle Zellen der ersten Reihe in den *Bypass*-Zustand, bevor der Fehler  $f_{R_{con,2}}$  isoliert wurde. Abbildung 5.20 zeigt die zugehörigen Schaltzustände, die Wahrscheinlichkeiten für die beiden wahrscheinlichsten Fehler, mit und ohne Detektierbarkeitsmaß, sowie das Detektierbarkeitsmaß für beide Fehler. In der Konfiguration  $s = 1$ , die der Konfiguration  $s = 2$  in Abbildung 5.19 entspricht, ist  $f_{R_{act,on,2}}$  strukturell nicht detektierbar und  $f_{R_{con,2}}$  strukturell, aber nicht analytisch detektierbar. Die schlechte analytische Detektierbarkeit lässt sich auch anhand der Residuen in Abbildung 5.19 für  $s = 2$  beobachten. Die Residuen liegen während des Zeitraums, in dem sich die Zellen der ersten Reihe im *Bypass*-Zustand befinden, nahe Null. Ohne ein Detektierbarkeitsmaß würde der Algorithmus zur aktiven Fehlerisolierung fälschlicherweise auf den Fehler  $f_{R_{act,on,2}}$  schließen. Durch Anwendung des Detektierbarkeitsmaßes  $\mathcal{D} \in [0, 1]$ , gemäß Definition 5.1, bleiben jedoch beide Fehler gleichwahrscheinlich, da beide Fehler nach dem Schaltvorgang analytisch nicht detektierbar sind.



**Abbildung 5.19:** Experimentelle Ergebnisse für die Diagnose von  $f_{R_{con,2}}$ . Von oben nach unten: Schaltzustände für die erste Reihe von RBS-Zellen, Wahrscheinlichkeit für die beiden wahrscheinlichsten Fehler, geschätzte Fehleramplitude  $f_i$ , gemessene Zellströme  $i_{Zelle,i}$ , gemessene Zellspannungen  $v_{Zelle,i}$ , Wert der Residuen  $r$ .



**Abbildung 5.20:** Experimentelle Ergebnisse für den Fehler  $f_{R_{con,2}} = 79.1 \text{ m}\Omega$ , der ab  $t = 317 \text{ s}$  emuliert wird. Von oben nach unten: Schaltzustände der ersten Reihe, Entscheidung des aktiven Diagnose-Algorithmus mit und ohne Detektierbarkeitsmaß, Detektierbarkeitsmaße der Fehler.

## 5.8 Ergebnisse und Fazit zur aktiven Fehlerdiagnose

Das entwickelte Framework zur aktiven, modellbasierten Fehlerdiagnose in RBSs basiert auf einer strukturellen Analyse des zugrundeliegenden elektro-thermischen Modells. Die resultierende Isolierbarkeitsanalyse hat gezeigt, dass die Verwendung eines thermischen Modells die Fehlerisolierbarkeit aus struktureller Sicht erhöht. Es sollte jedoch berücksichtigt werden, dass die Gleichungen des thermischen Modells zusätzliche Parameter und Modellunsicherheiten enthalten. Basierend auf der identifizierten Isolierbarkeitsmatrix findet Abschnitt 5.3.1 eine minimale Sensormenge mit optimalen Isolationseigenschaften. Diese besteht aus der Messung jeder Zellspannung, jedes Zellstroms, jeder Zelltemperatur und der redundanten Messung des Gesamtstroms und der Gesamtspannung im System. Aufgrund der hohen Systemredundanz, der Vielzahl an Modellgleichungen und der Komplexitätsprobleme bestehender Ansätze stellt die vorliegende Arbeit einen neuartigen Algorithmus vor, der das jeweils beste MSO-Set für jeden betrachteten Fehler in einem RBS findet. Die Methode identifiziert effizient die MSO-Teilmengen mit den wenigsten Gleichungen für jeden Fehler. Ein Vergleich mit bestehenden Ansätzen zum Finden von MSO-Subsystemen zeigt die Überlegenheit des vorgestellten Algorithmus in Systemen mit vielen Gleichungen und hoher Redundanz. Diese

Eigenschaft öffnet den Algorithmus über seine Anwendung in RBSs hinaus und macht ihn vielversprechend für alle Systeme, die eine große Anzahl an Modellgleichungen und hohe Redundanz haben, was zu vielen MSO-Subsystemen führt. Unter der Annahme, dass jede Modellgleichung die gleiche Unsicherheit hat, sind die gefundenen MSO-Sets optimal. Wenn jedoch die Modellunsicherheiten für jede Gleichung bekannt sind, kann der Algorithmus weiterentwickelt werden, indem die tatsächlichen Modellunsicherheiten berücksichtigt werden. Die Anwendung des Algorithmus zum Finden der kleinsten MSO-Sets hat gezeigt, dass die Methode die elektrischen Modellgleichungen gegenüber den thermischen Modellgleichungen priorisiert, auch wenn gültige MSO-Sets existieren. Dies liegt daran, dass die MSO-Mengen, die die thermischen Gleichungen enthalten, größer sind als diejenigen, die die elektrischen Gleichungen enthalten. Daher ist eine zusätzliche Unsicherheit zu erwarten.

Die anschließende Fehlerdetektion und aktive Fehlerisolation basieren auf Residuen, die aus den resultierenden MSO-Sets generiert werden. Das Diagnosesystem besteht aus einem residuenbasierten, beschränkten Parameter-Schätzer, einer Fehlererkennung mittels eines  $\chi^2$ -Tests und einer Fehlerisolierung mittels eines Fuzzy-Algorithmus. Die aktive Fehlerisolierung basiert auf einem aktiven sequentiellen Hypothesentest. Ein Nachweisbarkeitsmaß für jeden Fehler erhöht die Robustheit. Die entwickelten Algorithmen wurden simulativ und experimentell an einem rekonfigurierbaren Modul, bestehend aus sechs Lithium-Ionen-Zellen in 2s3p-Konfiguration, validiert. Die simulativen Untersuchungen haben gezeigt, dass der aktive Ansatz geeignet ist, die Fehlerisolation zu verbessern. Das Hinzufügen von Systemwissen, wie beispielsweise das Wissen über das Vorzeichen eines Fehlers, erhöht das Fehlerisoliationsvermögen weiter. Für die betrachtete Anwendung resultiert daraus eine unsymmetrische Isolationsmatrix. Es hat sich gezeigt, dass die minimal detektierbare Fehleramplitude signifikant von der Sensorqualität abhängt und zudem von der Abtastrate der Sensorik beeinflusst wird. Das Vorzeichen des Fehlers hat jedoch in der vorliegenden Anwendung keinen Einfluss auf die minimale detektierbare Fehleramplitude. Die experimentellen Ergebnisse haben gezeigt, dass ein Parameterschätzer für die modellbasierte Fehlerdiagnose auf dem realen System unerlässlich ist, da die Parameterwerte von Zelle zu Zelle variieren. Auch der Kontaktwiderstand zwischen Zelle und Stromschiene ändert sich mit jedem Versuchsaufbau. Ohne Parameterschätzung müsste das Prozessrauschen des Modells erhöht werden, was die Diagnose-Präzision des Algorithmus deutlich verringert. Da eine Vielzahl an Parametern zu schätzen ist, löst diese Aufgabe ein beschränktes SPKF, das harte und weiche Beschränkungen für alle Parameter besitzt. Um die Vorteile einer aktiven Fehlerdiagnose zu demonstrieren, wird das Diagnosesystem an einem experimentellen Modulprüfstand validiert, der eine Emulation eines ISC und eines erhöhten Kontaktwiderstands erlaubt. Der Algorithmus detektiert und isoliert beide Fehler korrekt. Die Wirksamkeit des eingeführten Detektierbarkeitsmaßes, das die Robustheit erhöht, wurde experimentell mit dem erhöhten Kontaktwiderstand validiert.



## 6 Zusammenfassung und Ausblick

Die vorliegende Arbeit befasst sich mit Methoden zur erweiterten Fehlerdiagnose in Lithium-Ionen-Batteriesystemen. Kapitel 4 entwickelt einen datengetriebenen Ansatz zur Diagnose interner Kurzschlüsse in konventionellen und Kapitel 5 einen aktiven, modellbasierten Ansatz für rekonfigurierbare Batteriesysteme. Durch ein nichtlineares Monitoring-Verfahren, basierend auf der KPCA, lässt sich die Detektionszeit interner Kurzschlüsse verkürzen. Ein wesentlicher Vorteil rekonfigurierbarer Batteriesysteme, bezogen auf die Diagnose von Fehlern, besteht in einer verbesserten Fehlerisolation. Die bessere Lokalisierung resultiert zum einen aus der gesteigerten Sensoranzahl und zum anderen aus den erweiterten Möglichkeiten, die eine aktive Rekonfiguration des Batteriesystems bietet. Das vorgestellte Matrix-Vektor-basierte Modell für große Batteriepacks erweist sich als hilfreiches Werkzeug für die Entwicklung der Verfahren. Es lässt sich als Referenzmodell und zur simulativen Validierung der Methoden einsetzen. Die nachfolgenden Abschnitte fassen die wichtigsten Ergebnisse der durchgeführten Untersuchungen zusammen und geben einen Ausblick.

### 6.1 Modellbildung großer Batteriepacks

Das entwickelte vektorisierte Zellmodell erlaubt die Abbildung des elektrischen und thermischen Verhaltens aller Zellen unter Berücksichtigung von Parametervariationen und zyklischer Alterung. Da im Batteriepack parallel geschaltete Zellen elektrisch und benachbarte Zellen thermisch interagieren, ist es für ein Modell auf Systemebene entscheidend, diese Wechselwirkungen zu berücksichtigen. Die experimentelle Validierung erfolgte anhand eines Batteriemoduls. Die Charakterisierung zweier Zelltypen hat zudem gezeigt, dass die Parameter der Zellen eine signifikante Abhängigkeit vom Ladezustand und der Temperatur besitzen, weshalb auch diese Einflüsse in das Modell einfließen. Der ganzheitliche Ansatz hat den Vorteil, dass neben den direkt messbaren Zellgrößen, wie Strom, Spannung und Temperatur, stets die Kenntnis über die internen Zellzustände gegeben ist und diese auch initialisiert werden können. Dies ist besonders für die Entwicklung von Diagnose-Algorithmen vorteilhaft, da für die Kenntnis interner Zustände in realen Anwendungen ansonsten Schätzverfahren benötigt werden. Zudem ist für die Fehlerdiagnose eine Simulation von Fehlerfällen zur Validierung der entwickelten Algorithmen relevant. Die simulierten Fehler gingen stets mit einer inhomogenen Strom- und

Temperaturverteilung im Batteriepack einher, woraus im Modell eine inhomogene Zellalterung resultierte.

Die im Rahmen dieser Arbeit entwickelten Modelle und Verfahren bereiten den Weg für die Beantwortung weiterer noch offener Forschungsfragen. So bietet das Modell des gesamten Batteriepacks die Möglichkeit, den Einfluss initialer Parameterunterschiede auf die Leistung und die Gesamtkapazität des Batteriesystems, das heißt die Reichweite des Elektrofahrzeugs, zu untersuchen. Auch wenn erste Ansätze in diesem Forschungsgebiet existieren, verspricht die Flexibilität und die Effizienz des entwickelten Systemmodells hier neue Erkenntnisse [12, 42]. Zudem lassen sich die Auswirkungen verschiedener Betriebsstrategien oder beispielsweise die Änderung der SOC-Grenzen untersuchen. Ein weiterer Ansatzpunkt wäre die Untersuchung, wie sich initiale Parameterunterschiede mit fortschreitender Alterung des Batteriepacks entwickeln und welche Vorschriften sich für ein intelligentes Batteriemanagement ergeben, sofern die Alterungseffekte nicht selbstbalancierend sind. Das effiziente Systemmodell eignet sich als Referenzmodell für die Entwicklung zukünftiger Algorithmen oder, beispielsweise in einer Hardware-in-the-Loop-Simulation, für die Entwicklung von Batteriemanagementsystemen. Zudem erlaubt die Generierung einer großen synthetischen Datenbank das Training weiterer datengetriebener Methoden.

## 6.2 Diagnose interner Kurzschlüsse in konventionellen Batteriesystemen

Der Diagnoseansatz der vorliegenden Arbeit zielt darauf ab, ISCs in der frühen, latenten Phase zu erkennen, bevor eine ausgeprägte Wärmegenerierung an der Oberfläche der Batteriezelle messbar ist. Um eine hohe Empfindlichkeit zu erreichen, stellt Kapitel 4 einen datengetriebenen Ansatz vor, der auf den Zellspannungsunterschieden innerhalb des Batteriepacks basiert. Da in konventionellen Batteriepacks eine hohe Homogenität angestrebt wird, werden die Spannungsdifferenzen vor allem von Sensorrauschen dominiert. In diesem Fall sind bereits mit einer linearen Prozessmonitoring-Methode, die auf der PCA basiert, eine Anomalieerkennung und Fehlerisolation möglich. Das mit zunehmender Alterung einhergehende nicht-stationäre Verhalten erfordert jedoch eine kontinuierliche Anpassung des Datenmodells. Diese Adaption kann durch eine rekursive Erweiterung oder eine Erweiterung des Verfahrens mit gleitenden Fenstern erfolgen. Für die mit dem Batteriemodell simulierte beschleunigte Alterung zeigt das rekursive Verfahren im Test eine geringere Fehleralarmrate.

Zur Frühdetektion interner Kurzschlüsse ist vor allem eine hohe Sensitivität auf beginnende Anomalien in den Zellspannungsunterschieden entscheidend. Mit zunehmender Alterung der Zellen dominieren jedoch nichtlineare Variationen der Spannungsdifferenzen das Sensorrauschen. Mit Hilfe der KPCA lernt der Algorithmus deshalb ein nichtlineares Datenmodell und



setzt dieses zur Online-Erkennung von ISCs ein. Die Kombination mehrerer Kernel-Funktionen ermöglicht eine frühzeitige Detektion und ein robustes Verhalten für fortgeschrittene ISCs, während gleichzeitig eine hohe Empfindlichkeit für Soft-ISCs erhalten bleibt. Die Identifikation einer Pareto-Front für die Fehlalarmrate und die MDR lässt eine optimale Wahl der Parameter zu. Dabei zeigt sich, dass die Detektionsleistung abseits von extrem gewählten Werten eine geringe Sensitivität bezüglich der Parameter besitzt. Mit der nichtlinearen Methode geht ein gesteigerter Rechenaufwand einher. Während der Rechenaufwand der linearen Methode maßgeblich von der Anzahl der Spannungssignale, also der Anzahl serieller Zellen im Batteriepack, bestimmt wird, ist für die nichtlineare Methode die Anzahl der Trainingsdaten entscheidend. Geeignete Matrixapproximationen reduzieren den Rechenaufwand jedoch auf die Größenordnung des linearen Verfahrens. Um auch für gemischte Kernel-Funktionen eine Fehlerisolation zu ermöglichen, entwickelt die vorliegende Arbeit, aufbauend auf bekannte Verfahren, eine geeignete Methode. Um die Anwendbarkeit des Ansatzes in Anwesenheit von Zellinkonsistenzen zu untersuchen, erfolgt eine experimentelle Validierung der Methode unter anderem an einem kalendarischen und zyklisch gealterten Batteriemodul mit unterschiedlichen Kurzschlusswiderständen. Ein Vergleich mit bekannten Methoden zeigt eine signifikante Reduktion der Detektionszeit.

Das datengetriebene Diagnoseverfahren zur ISC-Erkennung detektiert Anomalien in den Spannungsdifferenzen zwischen den Zellen. Diese Anomalien werden jedoch neben ISCs ganz allgemein durch eine Änderung der Selbstentladerate einer Zelle im Vergleich zur Mehrheit der Zellen verursacht. Auch eine Änderung des Coulombschen Wirkungsgrades einer auffälligen Zelle führt zu Spannungsinkonsistenzen. Die Detektion dieser Anomalien ist ein vielversprechender Ansatzpunkt für zukünftige Arbeiten. Wie bei der Zellcharakterisierung für die Parametrierung des Batteriepackmodells gezeigt, ändert sich die Ruhespannung der Zellen bei einer Temperaturänderung von  $\Delta T_c = 30 \text{ K}$  um bis zu 6 mV. Erwärmt sich also eine Zelle im Vergleich zu den restlichen Zellen, so ist diese Anomalie bei ausreichender Sensorqualität in den Spannungsdifferenzen zwischen den Zellen zu beobachten. Mit der in Abschnitt 4.5.9 gezeigten Sensitivität lässt sich eine Auffälligkeit in dieser Größenordnung detektieren. Der Algorithmus hat deshalb das Potential, auch eine anomale Wärmegenerierung im Zellwickel zu erkennen, bevor ein Temperaturanstieg auf der Zelloberfläche zu beobachten ist. Gerade bei großformatigen Zellen liefern die Spannungsdifferenzen einen vielversprechenden Einblick in das Innere der Zelle. Neben der Anwendung des Diagnoseverfahrens auf Spannungen ist auch eine Applikation auf weitere Sensorgrößen, wie Temperaturmesswerte denkbar. Aufgrund der komplexeren Wechselwirkungen der thermischen Größen könnte die Fehlerisolation dabei aber herausfordernder werden. Für ein ganzheitliches Monitoring wäre ein weiterer Ansatzpunkt die Kombination mehrerer Variablen, wie Strom, Spannung und Temperatur. Zudem lässt sich analog zur Theorie polynomialer Modelle die Dynamik dieser Variablen beobachten [142, 159]. Bei der Kombination mehrerer Variablen sowie der Berücksichtigung der Dynamik ist jedoch zu erwarten, dass sich die Interpretierbarkeit des Datenmodells zunehmend reduziert.

## 6.3 Aktive Fehlerdiagnose in rekonfigurierbaren Batteriesystemen

Um die erweiterten Möglichkeiten von RBSs bezogen auf die Fehlerdiagnose zu untersuchen, erfolgt eine strukturelle Analyse eines rekonfigurierbaren Moduls. Basierend auf den zugrundeliegenden elektro-thermischen Modellgleichungen ermöglicht die strukturelle Analyse das Finden einer minimalen Sensormenge mit optimalen Fehlerisolationseigenschaften. Da das System aus einer Vielzahl an Gleichungen besteht und deshalb bestehende Ansätze Komplexitätsprobleme besitzen, führt die vorliegende Arbeit einen neuartigen Algorithmus zur effizienten Berechnung von MSO-Teilsystemen für die Fehlerdiagnose ein. Der Ansatz erlaubt es, für jeden Fehler die MSO-Menge mit der geringsten Anzahl an Gleichungen zu bestimmen. Eine Komplexitätsanalyse zeigt, dass der vorgeschlagene Algorithmus für Systeme mit hoher Redundanz, wie RBSs, rechnerisch deutlich effizienter ist als die aus der Literatur bekannten Ansätze, die alle MSO-Sets berechnen. Die gefundenen MSO-Sets erlauben die Generierung von Residuen, also Abweichungen zwischen Sensormessungen und Modell. Der gewählte Ansatz zur Fehlerdetektion wertet diese Residuen stochastisch aus; die Fehlerisolierung ermöglicht ein Fuzzy-Clustering-Ansatz. Parallel zum Residuengenerator minimiert ein beschränktes SPKF die Modellunsicherheiten und erhöht somit die Sensitivität und Robustheit des Verfahrens. Darüber hinaus ermöglicht das Filter eine Schätzung der Fehleramplitude im Fehlerfall. Basierend auf aktiver sequentieller Hypothesenprüfung wird ein Verfahren zur Berechnung der nächsten Schalterstellung vorgeschlagen und untersucht. Der Ansatz nutzt die Schalter des RBSs, um die Struktur des Systems so zu verändern, dass sich nicht isolierbare Fehler unterscheiden lassen. Die simulativen und experimentellen Untersuchungen zeigen, dass sich zusätzliche Fehler durch den vorgestellten aktiven Ansatz isolieren lassen.

Der entwickelte Algorithmus zum Finden von MSO-Mengen in großen Systemen mit vielen Gleichungen und einer hohen Redundanz ebnet den Weg für die Anwendung der strukturellen Analyse in derartigen Systemen. Zudem ermöglichen die berücksichtigten Validitätsbedingungen die Anwendung in Systemen, die rekonfigurierbar sind. Die Ergebnisse an einem rekonfigurierbaren Batteriemodul haben gezeigt, dass bereits passive Fehlerdiagnose-Algorithmen aufgrund der hohen Sensoranzahl gute Isolationseigenschaften besitzen. Das Isolationsvermögen wird jedoch durch die aktive Fehlerdiagnose weiter verbessert, insbesondere innerhalb der Batteriezelle und zwischen den Zellen. Aus diesem Grund ist aktive Fehlerdiagnose besonders vielversprechend für Systeme mit weniger Sensoren oder zur Reduzierung der Anzahl der Sensoren. Ein Ansatzpunkt für die zukünftige Forschung ist die Untersuchung des optimalen Zusammenspiels der aktiven Fehlerdiagnose mit weiteren Algorithmen, die Schaltanforderungen mit sich bringen. Dazu gehören das schalterbasierte Balancieren, der Ausgleich des SOHs (*Wear-Leveling*) oder der Betrieb des RBSs als modularer Multilevel-Umrichter. Für


einen effizienten Betrieb sollte unter Berücksichtigung aller Funktionen das globale Optimum zur Ansteuerung der Schalter gefunden werden. Aufgrund der vorangegangenen strukturellen Analyse basiert das vorgestellte Diagnosesystem auf der *Single-Fault-Annahme*. Da sich das aktive Diagnosesystem jedoch nicht auf diese Einschränkung stützt, bietet die Anwendung mit mehreren Fehlern eine vielversprechende Erweiterung des Diagnosesystems. RBSs ermöglichen auf Fehler zu reagieren, beispielsweise durch das Überbrücken einer fehlerhaften Zelle. Das vorgestellte Diagnose-Framework bildet somit die Grundlage für die Fehlertoleranz in RBSs.



# A Anhang

## A.1 Messungen an den PAN-Zellen

Ergänzend zu den in den Abschnitten 2.2.2 und 2.2.3 gezeigten Messungen an der SMG-Zelle zeigen die nachfolgenden Abbildungen die entsprechenden Messungen an der PAN-Zelle. Es handelt sich dabei um einen Kapazitätstest (Abbildung A.1), um einen POCV-Test (Abbildung A.2), einen HPPC-Test (Abbildung A.3), eine dynamische Entladung (Abbildung A.4) und um einen Konstantstrom-Test (Abbildung A.5).



**Abbildung A.1:** Kapazitätstest einer PAN-Zelle bei unterschiedlichen Temperaturen.




Abbildung A.2: Test zur Ermittlung der POCV einer PAN-Zelle.






Abbildung A.3: HPPC-Test zur Parameteridentifikation einer PAN-Zelle.



**Abbildung A.4:** Dynamische Entladung einer PAN-Zelle mit einem WLTP-basierten Stromprofil zur Validierung der identifizierten Parameter.



**Abbildung A.5:** Konstantstromentladung und -ladung einer PAN-Zelle mit dem maximal zulässigen Ladestrom zur Ermittlung des maximalen Widerstands.

## A.2 Graphische Oberfläche des Modell-Frameworks

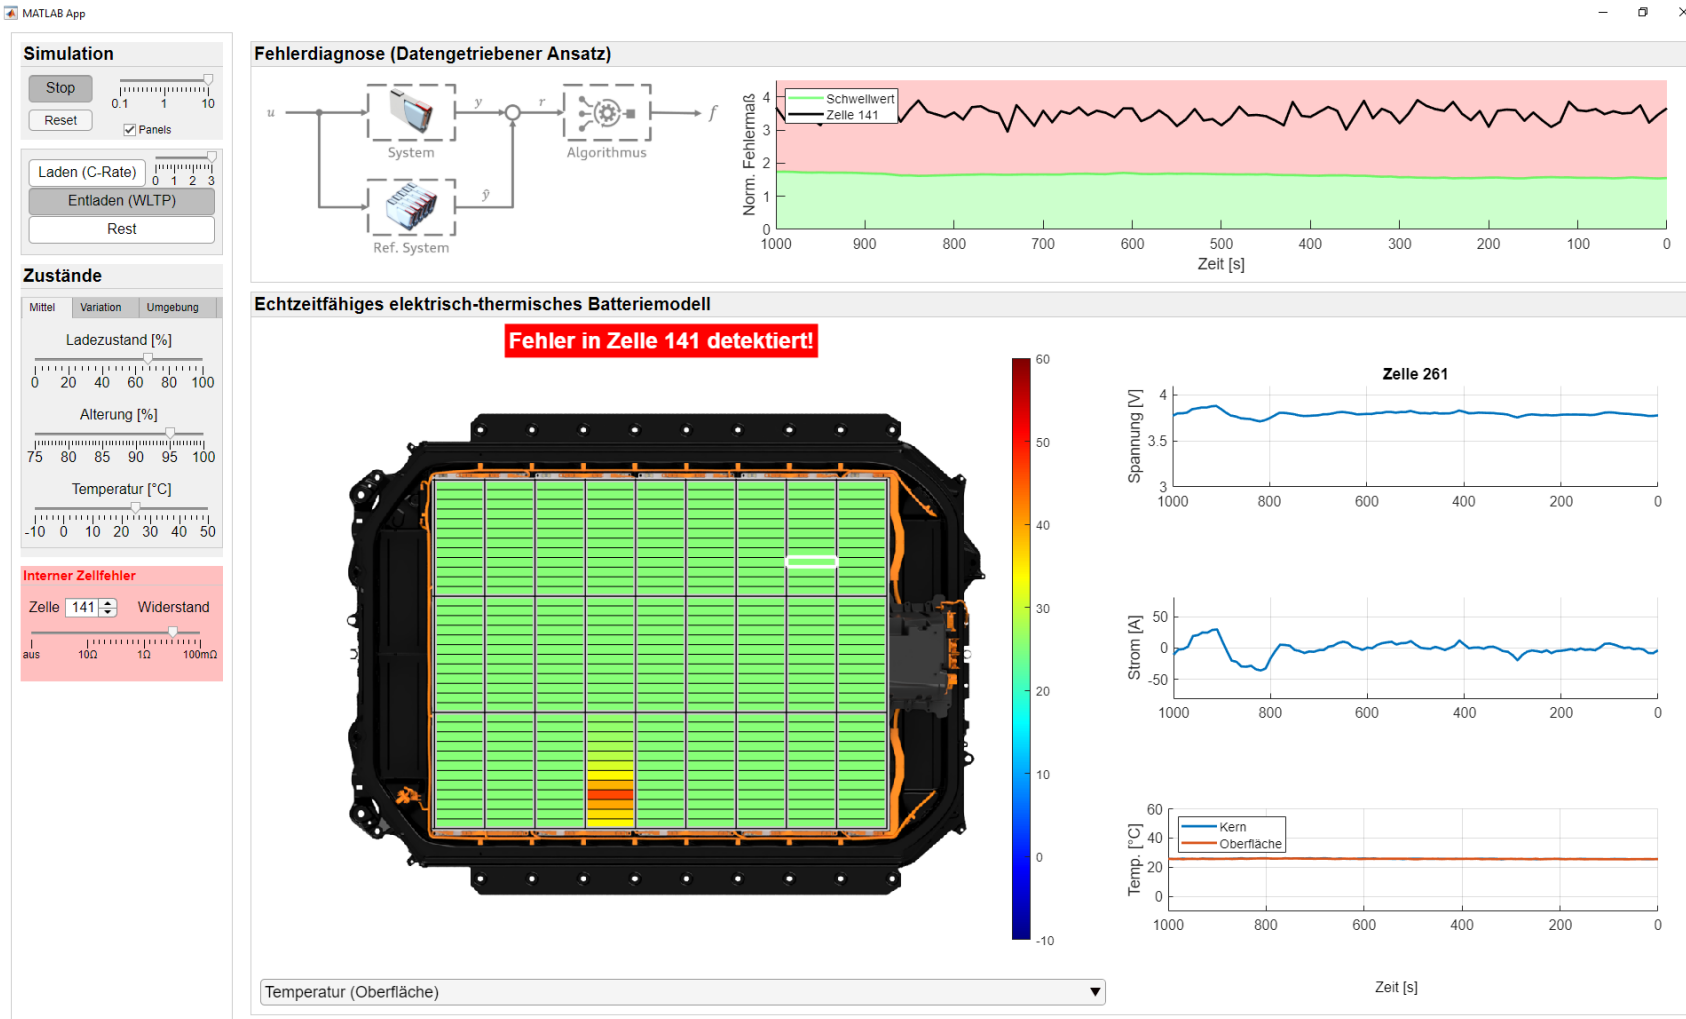


Abbildung A.6: Graphische Oberfläche des Modell-Frameworks während der Simulation eines internen Kurzschlusses einer Zelle



## A.3 Rang-1-Modifikation des symmetrischen Eigenwertproblems

Sowohl die RPCA als auch die MWPCA erfordern eine Anpassung der Eigenwertzerlegung im Falle einer Aktualisierung der symmetrischen, positiv definiten Kovarianzmatrix. In der Literatur existiert eine Reihe von Verfahren für die Lösung dieses Problems. Dazu zählen neben der Rang-1-Modifikation die Inverse Iteration, das Lanczos-Verfahren, die Perturbation erster Ordnung, die projektionsbasierte Adaption und die Datenprojektionsmethode sowie – weniger effiziente – Gradientenabstiegsverfahren [151]. Im Rahmen dieser Arbeit kommt die in der Literatur häufig verwendete und effiziente Rang-1-Modifikation zur Anwendung [128, 215]. Erfolgt eine Aktualisierung der Kovarianzmatrix

$$\mathbf{C}_{k+1} = \frac{N_k - 1}{N_k} \mathbf{C}_k + \frac{1}{N_k} \mathbf{z}_{k+1} \mathbf{z}_{k+1}^T \in \mathbb{R}^{m \times m} \quad (\text{A.333})$$

mit dem neuen Datenvektor  $\mathbf{z}_{k+1}$ , so folgt die Eigenwertzerlegung

$$\begin{aligned} \mathbf{C}_k &= \mathbf{P}_k \mathbf{\Lambda}_k \mathbf{P}_k^T \\ \mathbf{C}_{k+1} &= \mathbf{P}_{k+1} \mathbf{\Lambda}_{k+1} \mathbf{P}_{k+1}^T. \end{aligned} \quad (\text{A.334})$$

Mit der Definition  $\boldsymbol{\rho}_{k+1} = \mathbf{P}_k^T \mathbf{z}_{k+1}$  folgt aus (A.333) und (A.334):

$$\mathbf{P}_{k+1} (N_k \mathbf{\Lambda}_{k+1}) \mathbf{P}_{k+1}^T = \mathbf{P}_k [(N_k - 1) \mathbf{\Lambda}_k + \boldsymbol{\rho}_{k+1} \boldsymbol{\rho}_{k+1}^T] \mathbf{P}_k^T. \quad (\text{A.335})$$

Eine Eigenwertzerlegung von  $[(N_k - 1) \mathbf{\Lambda}_k + \boldsymbol{\rho}_{k+1} \boldsymbol{\rho}_{k+1}^T]$  liefert

$$[(N_k - 1) \mathbf{\Lambda}_k + \boldsymbol{\rho}_{k+1} \boldsymbol{\rho}_{k+1}^T] = \mathbf{V}_{k+1} \mathbf{D}_{k+1} \mathbf{V}_{k+1}^T. \quad (\text{A.336})$$

Die Substitution von (A.336) in (A.335) liefert die rekursiven Updateregeln:

$$\begin{aligned} \mathbf{P}_{k+1} &= \mathbf{P}_k \mathbf{V}_{k+1} \\ \mathbf{\Lambda}_{k+1} &= \mathbf{D}_{k+1} / N_k. \end{aligned} \quad (\text{A.337})$$

Seien die Diagonalmatrix  $\mathbf{Q}_{\mathbf{\Lambda},k+1}$  und die Matrix  $\mathbf{Q}_{\mathbf{V},k+1}$  kleine Störungsmatrizen und schreibt man  $\mathbf{D}_{k+1} = \mathbf{\Lambda}_k + \mathbf{Q}_{\mathbf{\Lambda},k+1}$  sowie  $\mathbf{V}_{k+1} = \mathbf{I} + \mathbf{Q}_{\mathbf{V},k+1}$ , so transformiert sich das Problem aus (A.337) in das Finden von  $\mathbf{Q}_{\mathbf{\Lambda},k+1}$  und  $\mathbf{Q}_{\mathbf{V},k+1}$  [128]. Peddaneni, Erdogmus u. a. leiten in ihrer Arbeit die Beziehung

$$\mathbf{Q}_{\mathbf{\Lambda},k+1} = \text{diag}(\rho_i^2) \quad (\text{A.338})$$

und für den  $(i,j)$ -ten Eintrag von  $\mathbf{Q}_{V,k+1}$  die Beziehung

$$\mathbf{Q}_{V,k+1}(i, j) = \begin{cases} 0 & \text{für } i = j \\ \frac{\rho_i \rho_j}{\lambda_j + \rho_j^2 - \lambda_i - \rho_i^2} & \text{für } i \neq j \end{cases} \quad (\text{A.339})$$

her, wobei  $\rho_i$  das  $i$ -te Element von  $\boldsymbol{\rho}_{k+1}$  ist und  $\lambda_i$  das  $i$ -te Diagonalelement von  $\mathbf{\Lambda}_k$  ist [215]. Um Instabilitäten zu verhindern, wenn zwei aufeinanderfolgende Eigenwerte sehr nah beieinander sind, erweitert Jeng die Berechnungsvorschrift um den folgenden Stabilisierungsmechanismus

$$\mathbf{Q}_{V,k+1}(i, j) = \begin{cases} 0 & \text{für } i = j \\ \frac{\rho_i \rho_j}{\max(\delta \lambda_1, \lambda_j + \rho_j^2 - \lambda_i - \rho_i^2)} & \text{für } i > j \\ \frac{\rho_i \rho_j}{\min(-\delta \lambda_1, \lambda_j + \rho_j^2 - \lambda_i - \rho_i^2)} & \text{für } i < j, \end{cases} \quad (\text{A.340})$$

wobei  $\delta$  eine kleine positive Zahl ist [128].

## A.4 Summenumformung zur rekursiven Berechnung der Standardabweichung

Gleichung (A.341) zeigt die Umformung von Gleichung (4.188) nach Gleichung (4.189) zur rekursiven Berechnung der Standardabweichung für die RPCA:

$$(N_{k+1} - 1)s_{c,k+1}^2 - \sum_{\tau=1}^{n_{k+1}} (\xi_{c,\tau} - \bar{\xi}_{c,k+1})^2 = \quad (\text{A.341a})$$

$$= \sum_{\tau=1}^{N_k} (\xi_{c,\tau} - \bar{\xi}_{c,k} - \Delta \bar{\xi}_{c,k+1})^2 \quad (\text{A.341b})$$

$$= \sum_{\tau=1}^{N_k} (\xi_{c,\tau}^2 - 2\xi_{c,\tau}\bar{\xi}_{c,k} - 2\xi_{c,\tau}\Delta \bar{\xi}_{c,k+1} + \bar{\xi}_{c,k}^2 + 2\bar{\xi}_{c,k}\Delta \bar{\xi}_{c,k+1} + \Delta \bar{\xi}_{c,k+1}^2) \quad (\text{A.341c})$$

$$= \sum_{\tau=1}^{N_k} (\xi_{c,\tau}^2 - 2\xi_{c,\tau}\bar{\xi}_{c,k} + \bar{\xi}_{c,k}^2) + \sum_{\tau=1}^{N_k} (-2\xi_{c,\tau}\Delta \bar{\xi}_{c,k+1} + 2\bar{\xi}_{c,k}\Delta \bar{\xi}_{c,k+1}) + \sum_{\tau=1}^{N_k} \Delta \bar{\xi}_{c,k+1}^2 \quad (\text{A.341d})$$

$$= \sum_{\tau=1}^{N_k} (\xi_{c,\tau} - \bar{\xi}_{c,k})^2 - 2\Delta \bar{\xi}_{c,k+1} \underbrace{\sum_{\tau=1}^{N_k} (\xi_{c,\tau} - \bar{\xi}_{c,k})}_{=0} + N_k \Delta \bar{\xi}_{c,k+1}^2 \quad (\text{A.341e})$$

$$= \sum_{\tau=1}^{N_k} (\xi_{c,\tau} - \bar{\xi}_{c,k})^2 + N_k \Delta \bar{\xi}_{c,k+1}^2. \quad (\text{A.341f})$$

## A.5 Zentrierung von Abbildungen im Merkmalsraum $\mathbb{F}$

Dieser Abschnitt geht auf die Zentrierung der Trainingsdatenmatrix (Abschnitt A.5) und die Zentrierung eines neuen Testdatenvektors (Abschnitt A.5) im Merkmalsraum ein.

### Trainingsdatenmatrix

Nach Gleichung (4.213) ist die Kernel-Funktion definiert als

$$\kappa(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = \Phi(\mathbf{z}_{\tau_1})^T \Phi(\mathbf{z}_{\tau_2}), \quad (\text{A.342})$$

mit  $\tau_1, \tau_2 \in [1, N]$ . Nach Gleichung (4.218) erfolgt die Zentrierung von  $\tilde{\Phi}(\cdot)$  gemäß

$$\Phi(\mathbf{z}_\tau) = \tilde{\Phi}(\mathbf{z}_\tau) - \frac{1}{N} \sum_{i=1}^N \tilde{\Phi}(\mathbf{z}_i). \quad (\text{A.343})$$

Das Substituieren von (A.5) in (A.342) liefert

$$\kappa(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = \left( \tilde{\Phi}(\mathbf{z}_{\tau_1}) - \frac{1}{N} \sum_{i=1}^N \tilde{\Phi}(\mathbf{z}_i) \right)^T \left( \tilde{\Phi}(\mathbf{z}_{\tau_2}) - \frac{1}{N} \sum_{j=1}^N \tilde{\Phi}(\mathbf{z}_j) \right) \quad (\text{A.344a})$$

$$\begin{aligned} &= \tilde{\Phi}(\mathbf{z}_{\tau_1})^T \tilde{\Phi}(\mathbf{z}_{\tau_2}) - \frac{1}{N} \sum_{i=1}^N \tilde{\Phi}(\mathbf{z}_i)^T \tilde{\Phi}(\mathbf{z}_{\tau_2}) \\ &\quad - \frac{1}{N} \sum_{j=1}^N \tilde{\Phi}(\mathbf{z}_{\tau_1})^T \tilde{\Phi}(\mathbf{z}_j) + \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \tilde{\Phi}(\mathbf{z}_i)^T \tilde{\Phi}(\mathbf{z}_j). \end{aligned} \quad (\text{A.344b})$$

Die Abbildungen  $\Phi(\cdot)$  in den Merkmalsraum treten in Gleichung (A.344b) nur in Form von Skalarprodukten auf. Die Anwendung der Kernel-Funktion (A.342) erlaubt deshalb, die Zentrierung ohne Berechnung der expliziten Abbildung durchzuführen:

$$\kappa(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) = \tilde{\kappa}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) - \frac{1}{N} \sum_{i=1}^N \tilde{\kappa}(\mathbf{z}_i, \mathbf{z}_{\tau_2}) - \frac{1}{N} \sum_{j=1}^N \tilde{\kappa}(\mathbf{z}_{\tau_1}, \mathbf{z}_j) + \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \tilde{\kappa}(\mathbf{z}_i, \mathbf{z}_j). \quad (\text{A.345})$$

In Matrix-Vektor-Notation folgt für die Zentrierung der nicht-zentrierten Kernel-Matrix

$$\tilde{\mathbf{K}} = \begin{bmatrix} \tilde{\kappa}(\mathbf{z}_1, \mathbf{z}_1) & \dots & \tilde{\kappa}(\mathbf{z}_1, \mathbf{z}_{\tau_2}) & \dots & \tilde{\kappa}(\mathbf{z}_1, \mathbf{z}_N) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \tilde{\kappa}(\mathbf{z}_{\tau_1}, \mathbf{z}_1) & \dots & \tilde{\kappa}(\mathbf{z}_{\tau_1}, \mathbf{z}_{\tau_2}) & \dots & \tilde{\kappa}(\mathbf{z}_{\tau_1}, \mathbf{z}_N) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \tilde{\kappa}(\mathbf{z}_N, \mathbf{z}_1) & \dots & \tilde{\kappa}(\mathbf{z}_N, \mathbf{z}_{\tau_2}) & \dots & \tilde{\kappa}(\mathbf{z}_N, \mathbf{z}_N) \end{bmatrix} \quad (\text{A.346})$$

die Vorschrift

$$\mathbf{K} = \tilde{\mathbf{K}} - \mathbf{1}_{N \times N} \tilde{\mathbf{K}} - \tilde{\mathbf{K}} \mathbf{1}_{N \times N} + \mathbf{1}_{N \times N} \tilde{\mathbf{K}} \mathbf{1}_{N \times N}. \quad (\text{A.347})$$

## Testdatenvektor

Mit

$$\tilde{\kappa}(\mathbf{z}_t, \mathbf{z}_\tau) = \tilde{\Phi}(\mathbf{z}_t)^T \tilde{\Phi}(\mathbf{z}_\tau) \quad (\text{A.348})$$

folgt nach Gleichung (4.218) für die Zentrierung einer neuen Beobachtung  $\tilde{\mathbf{k}}_t$ , basierend auf den Trainingsdaten  $\tau \in [1, N]$ , zum Zeitpunkt  $t$ :

$$\kappa(\mathbf{z}_t, \mathbf{z}_\tau) = \left( \tilde{\Phi}(\mathbf{z}_t) - \frac{1}{N} \sum_{i=1}^N \tilde{\Phi}(\mathbf{z}_i) \right)^T \left( \tilde{\Phi}(\mathbf{z}_\tau) - \frac{1}{N} \sum_{j=1}^N \tilde{\Phi}(\mathbf{z}_j) \right) \quad (\text{A.349a})$$

$$\begin{aligned} &= \tilde{\Phi}(\mathbf{z}_t)^T \tilde{\Phi}(\mathbf{z}_\tau) - \frac{1}{N} \sum_{i=1}^N \tilde{\Phi}(\mathbf{z}_i)^T \tilde{\Phi}(\mathbf{z}_\tau) \\ &\quad - \frac{1}{N} \sum_{j=1}^N \tilde{\Phi}(\mathbf{z}_t)^T \tilde{\Phi}(\mathbf{z}_j) + \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \tilde{\Phi}(\mathbf{z}_i)^T \tilde{\Phi}(\mathbf{z}_j). \end{aligned} \quad (\text{A.349b})$$

Die Skalarprodukt-Schreibweise von (A.349b) erlaubt eine Zentrierung von  $\tilde{\mathbf{k}}_t$  ohne explizite Berechnung der Abbildungen in den Merkmalsraum (*Kernel-Trick*):

$$\kappa(\mathbf{z}_t, \mathbf{z}_\tau) = \tilde{\kappa}(\mathbf{z}_t, \mathbf{z}_\tau) - \frac{1}{N} \sum_{i=1}^N \tilde{\kappa}(\mathbf{z}_i, \mathbf{z}_\tau) - \frac{1}{N} \sum_{j=1}^N \tilde{\kappa}(\mathbf{z}_t, \mathbf{z}_j) + \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \tilde{\kappa}(\mathbf{z}_i, \mathbf{z}_j). \quad (\text{A.350})$$

In Matrix-Vektor-Notation folgt die Vorschrift

$$\mathbf{k}_t = \tilde{\mathbf{k}}_t - \tilde{\mathbf{K}} \mathbf{1}_{N \times 1} - \mathbf{1}_{N \times N} \tilde{\mathbf{k}}_t + \mathbf{1}_{N \times N} \tilde{\mathbf{K}} \mathbf{1}_{N \times 1}. \quad (\text{A.351})$$

## A.6 Rekursiver Bayes-Schätzer

Detaillierte Herleitung von Gleichung (5.322) unter Verwendung des Satzes von Bayes und der Markov-Eigenschaft [30]:

$$P(\mathcal{H}_i | \Phi_{0:s}) \stackrel{\text{Bayes}}{=} \frac{P(\Phi_{0:s} | \mathcal{H}_i) P(\mathcal{H}_i)}{P(\Phi_{0:s})} \quad (\text{A.352a})$$

$$= \frac{P(\Phi_s, \Phi_{0:s-1} | \mathcal{H}_i) P(\mathcal{H}_i)}{P(\Phi_s, \Phi_{0:s-1})} \quad (\text{A.352b})$$

$$\stackrel{\text{Markov}}{=} \frac{P(\Phi_s | \Phi_{0:s-1}, \mathcal{H}_i) P(\Phi_{0:s-1} | \mathcal{H}_i) P(\mathcal{H}_i)}{P(\Phi_s | \Phi_{0:s-1}) P(\Phi_{0:s-1})} \quad (\text{A.352c})$$

$$\stackrel{\text{Bayes}}{=} \frac{P(\Phi_s | \Phi_{0:s-1}, \mathcal{H}_i) P(\mathcal{H}_i | \Phi_{0:s-1}) P(\Phi_{0:s-1}) P(\mathcal{H}_i)}{P(\Phi_s | \Phi_{0:s-1}) P(\Phi_{0:s-1}) P(\mathcal{H}_i)} \quad (\text{A.352d})$$

$$= \frac{P(\Phi_s | \mathcal{H}_i) P(\mathcal{H}_i | \Phi_{0:s-1})}{P(\Phi_s | \Phi_{0:s-1})} \quad (\text{A.352e})$$

$$\stackrel{\text{Bayes}}{=} \frac{P(\mathcal{H}_i | \Phi_s) P(\mathcal{H}_i) P(\mathcal{H}_i | \Phi_{0:s-1})}{P(\Phi_s) P(\Phi_s | \Phi_{0:s-1})}. \quad (\text{A.352f})$$

# Abkürzungen

<b>AS</b>	Aktiv-Schalter
<b>AU</b>	Artemis-Urban
<b>Bed.</b>	Bedingung
<b>BEV</b>	Batteriebetriebenes Elektrofahrzeug, Battery-Electric-Vehicle
<b>BMS</b>	Batteriemanagementsystem
<b>BS</b>	Bypass-Schalter
<b>CC</b>	Constant-Current
<b>CCCV</b>	Constant-Current-Constant-Voltage
<b>CD</b>	Entladungsmodus, Charge-Depleting-Modus
<b>CPU</b>	Zentrale Verarbeitungseinheit, Central-Processing-Unit
<b>CPV</b>	Kumulative prozentuale Varianz, Cumulative-Percentage-Variance
<b>CV</b>	Constant-Voltage
<b>DC</b>	Gleichstrom, Direct-Current
<b>DOD</b>	Entladetiefe, Depth-Of-Discharge
<b>DP</b>	Doppelpolarisation, Dual-Polarization
<b>DT</b>	Detektionszeit, Detection-Time
<b>ECM</b>	Elektrisches Ersatzschaltbildmodell, Electrical-equivalent-Circuit-Model
<b>EIS</b>	Elektrochemische Impedanzspektroskopie
<b>EKF</b>	Extended-Kalman-Filter
<b>ESC</b>	Externer Kurzschluss, External-Short-Circuit
<b>FAR</b>	Fehlalarmrate, False-Alarm-Rate

---

<b>HEV</b>	Hybridfahrzeug, Hybrid-Electric-Vehicle
<b>HPPC</b>	Hybrid-Pulse-Power-Characterization
<b>IBS</b>	Intelligentes Batteriesystem
<b>ICR</b>	Erhöhter Kontaktwiderstand, Increased-Contact-Resistance
<b>IEC</b>	Internationale elektrotechnische Kommission, International-Electrotechnical-Commission
<b>ISC</b>	Interner Kurzschluss, Internal-Short-Circuit
<b>KCL</b>	Kirchhoffsche Knotenregel, Kirchhoff's-Current-Law
<b>KPCA</b>	Kernbasierte Hauptkomponentenanalyse, Kernel-Principal-Component-Analysis
<b>KVL</b>	Kirchhoffsche Maschenregel, Kirchhoff's-Voltage-Law
<b>MDL</b>	Modellbasiert
<b>MDR</b>	Rate der verpassten Detektionen, Missed-Detection-Rate
<b>MOSFET</b>	Metal-Oxide-Semiconductor-Field-Effect-Transistor
<b>MSO</b>	Minimal strukturell überbestimmt, Minimal-Structurally-Overdetermined
<b>MWPCA</b>	Gleitende Hauptkomponentenanalyse, Moving-Window-Principal-Component-Analysis
<b>NEFZ</b>	Neuer Europäischer Fahrzyklus
<b>NMC</b>	Nickel-Mangan-Cobalt
<b>OCV</b>	Leerlaufspannung, Open-Circuit-Voltage
<b>ORSS</b>	Outlier-Robust-Sample-Studentization
<b>PAN</b>	<i>Panasonic UF261591</i> Batteriezelle
<b>PCA</b>	Hauptkomponentenanalyse, Principal-Component-Analysis
<b>PDG</b>	Partielle Differentialgleichung
<b>PHEV</b>	Plug-in-Hybridfahrzeug, Plug-in-Hybrid-Electric-Vehicle
<b>PI</b>	Proportional-Integral
<b>PNGV</b>	Partnership-for-New-Generation-of-Vehicles

---

<b>POCV</b>	Pseudo-Leerlaufspannung, Pseudo-Open-Circuit-Voltage
<b>PSO</b>	Geeignet strukturell überbestimmt, Properly-Structurally-Overdetermined
<b>RBF</b>	Radiale Basisfunktion
<b>RBS</b>	Rekonfigurierbares Batteriesystem
<b>RC</b>	Widerstand-Kapazität, Resistance-Capacitance
<b>RKHS</b>	Hilbertraum mit reproduzierendem Kern, Reproducing-Kernel-Hilbert-Space
<b>Rint</b>	Innenwiderstand, Internal-Resistance
<b>RLS</b>	Recursive-Least-Squares
<b>RMSE</b>	Wurzel der mittleren Fehlerquadratsumme, Root-Mean-Square-Error
<b>RPCA</b>	Rekursive Hauptkomponentenanalyse, Recursive-Principal-Component-Analysis
<b>SEI</b>	Solid-Electrolyte-Interphase
<b>SMG</b>	<i>Samsung INR18650-25R</i> Batteriezelle
<b>SOC</b>	Ladezustand, State-Of-Charge
<b>SOH</b>	Alterungszustand, State-Of-Health
<b>SPKF</b>	Sigma-Punkt-Kalman-Filter
<b>SVD</b>	Singulärwertzerlegung, Singular-Value-Decomposition
<b>SVM</b>	Stützvektormaschine, Support-Vector-Machine
<b>UCL</b>	Obere Kontrollgrenze, Upper-Control-Limit
<b>WLTP</b>	Worldwide-harmonized-Light-vehicles-Test-Procedure





# Symbole

## Mathematische Grundlagen

$(a, b)$	Tupel bestehend aus $a$ und $b$
$\{a, b\}$	Menge bestehend aus $a$ und $b$
$a, A$	kleine und große nicht-fette Buchstaben: Skalare
$\mathbf{a}$	Kleinbuchstaben, fett: Vektoren
$\mathbf{A}$	Großbuchstaben, fett: Matrizen
$a_{ij}$	Das $j$ -te Element in der $i$ -ten Zeile einer Matrix $\mathbf{A}$
$\mathbb{A}$	Großbuchstaben mit Doppelstrich: Mengen
$\mathbb{N}$	Menge der natürlichen Zahlen $\{1, 2, \dots\}$
$\mathbb{N}_0$	Menge der natürlichen Zahlen mit Null $\{0, 1, \dots\}$
$\mathbb{R}$	Menge der reellen Zahlen
$\mathbb{R}_{\geq 0}$	Menge der reellen Zahlen größer oder gleich Null
$\mathbb{R}_{> 0}$	Menge der reellen Zahlen echt größer Null
$\mathbb{C}$	Menge der komplexen Zahlen
$\Re(x)$	Realteil von $x$
$\Im(x)$	Imaginärteil von $x$
$\mathbf{0}_n$	$n$ -dimensionaler Null-Vektor
$\mathbf{0}_{m \times n}$	$m \times n$ -dimensionale Null-Matrix
$\mathbf{1}_n$	$n$ -dimensionaler Eins-Vektor
$\mathbf{1}_{m \times n}$	$m \times n$ -dimensionale Eins-Matrix
$\mathbf{I}_m$	$m \times m$ -dimensionale Einheitsmatrix
$\mathbf{a}^T$	transponierter Vektor von $\mathbf{a}$
$\mathbf{A}^T$	transponierte Matrix von $\mathbf{A}$
$\mathbf{A}^{-1}$	Inverse der Matrix $\mathbf{A}$
$\mathbf{A}^{\circ-1}$	Hadamard-Inverse der Matrix $\mathbf{A}$
$\mathbf{A}^p$	$p$ -te Potenz der Matrix $\mathbf{A}$
$\mathbf{A}^{\circ p}$	$p$ -te Hadamard-Potenz der Matrix $\mathbf{A}$
$\dot{a}$	Zeitliche Ableitung des Skalars $a$
$\bar{\mathbf{a}}$	Mittelwert des Vektors $\mathbf{a}$
$ \mathbf{a} $	Absolutwert des Vektors $\mathbf{a}$

$ \mathbb{A} $	Kardinalität der Menge $\mathbb{A}$
$\ \mathbf{a}\ $	Euklidische Norm $\ \mathbf{a}\  = \sqrt{\mathbf{a}^T \mathbf{a}}$ des Vektors $\mathbf{a}$
$\text{chol}(\mathbf{A})$	Cholesky-Zerlegung der Matrix $\mathbf{A}$
$\det(\mathbf{A})$	Determinante der Matrix $\mathbf{A}$
$\text{diag}(\mathbf{A})$	Vektor, bestehend aus den Diagonalelementen der Matrix $\mathbf{A}$
$\text{diag}\{\mathbf{a}\}$	Diagonalmatrix mit Diagonalelementen $\mathbf{a}$
$\text{diag}\{\mathbf{A}_j\}$	Blockdiagonalmatrix mit $j \in [1, n]$ Matrizen $\mathbf{A}_j$ auf der Diagonale
$\text{dim}(\mathbf{a})$	Länge des Vektors $\mathbf{a}$
$\text{rang}(\mathbf{A})$	Rang der Matrix $\mathbf{A}$
$\text{span}\{\mathbf{A}\}$	Lineare Hülle der Matrix $\mathbf{A}$
$a \vee b$	logische ODER-Verknüpfung von $a$ und $b$
$a \wedge b$	logische UND-Verknüpfung von $a$ und $b$
$\exp(\cdot)$	Exponentialfunktion
$\in$	Elementaussage
$\forall$	Allaussage
$\exists$	Existenzaussage
$:=$	Linksseitige Definition
$\mathbf{x} \sim \mathcal{N}(\cdot)$	$\mathbf{x}$ folgt einer Normalverteilung
$\circ$	Hadamard-Produkt (Elementweises Produkt $p$ )
$\oslash$	Hadamard-Division (Elementweise Division $p$ )
$[\cdot]$	Zeitdiskrete Wert oder elementweise Anwendung einer Funktion auf eine Matrix oder einen Vektor
$\frac{\partial(\cdot)}{\partial a}$	Partielle Ableitung erster Ordnung nach $a$

## Matrix-Vektor-basierte Modellbildung

$c_{\text{entr}}$	Entropischer Wärmekoeffizient [ $\text{V K}^{-1}$ ]
$\mathbf{C}_c$	Thermische Kapazität der Zellkerne [ $\text{J K}^{-1}$ ]
$\mathbf{C}_p$	Kapazitäten der Zellenpolarisation [F]
$\mathcal{C}_p$	Wertetabelle für $\mathbf{C}_p$
$\mathbf{C}_s$	Thermische Kapazität der Zelloberflächen [ $\text{J K}^{-1}$ ]
$\mathbf{CR}$	Laderate (C-Rate)
$\mathbf{DOD}$	Entladetiefe [Ah]
$\mathbf{E}$	Hilfsmatrix des Modells, siehe (3.113)
$\mathbf{E}_m$	Elektromotorische Kraft (OCV) [V]
$\mathcal{E}_m$	Wertetabelle für $\mathbf{E}_m$
$\mathbf{F}$	Hilfsmatrix des Modells, siehe (3.114)
$\mathbf{G}$	Hilfsmatrix des Modells, siehe (3.115)

$h$	Simulationsschrittweite [s]
$h_q$	Zellindividuelle Schrittweiten, basierend auf $q_\Sigma$ [Ah]
$\mathbf{H}$	Hilfsmatrix des Modells, siehe (3.116)
$i_{\{bp, bn\}}$	Ströme auf den Stromschienen [A]
$i_{\text{cell}}$	Zellströme [A]
$i_{\text{tot}}$	Batterie-Gesamtstrom [A]
$k$	Zeitschritt
$\mathbf{L}$	Hilfsmatrix des Modells, siehe (3.128)
$\mathbf{m}$	Hilfsvektor des Modells, siehe (3.118)
$\mathbf{M}$	Hilfsmatrix des Modells, siehe (3.117)
$n_{\text{cell}}$	Anzahl der Zellen
$n_{\text{mod}}$	Anzahl der Module
$n_{\text{par}}$	Anzahl paralleler Zellen
$n_{\text{RC}}$	Anzahl der RC-Elemente
$n_{\text{ser}}$	Anzahl serieller Zellen
$n_{\text{th}}$	Anzahl thermisch verbundener Zellen
$P_{\text{cell}}$	Gesamtwärmegenerierung der Zellen [W]
$P_{\text{entr}}$	Entropische Wärmegenerierung der Zellen [W]
$P_{\text{ext}}$	Externer Wärmestrom der Zellen [W]
$P_n$	Wärmestrom zwischen benachbarten Zellen [W]
$P_R$	Wärmegenerierung, verursacht durch $\mathbf{R}_{\{bp, bn, cp, cn\}}$ [W]
$P_{\text{res}}$	Resistive Wärmegenerierung der Zellen [W]
$q_\Sigma$	Gesamtladedurchsatz der Zellen [Ah]
$Q$	Zellkapazitäten [Ah]
$R_0$	Ohmscher Widerstand der Zellen [ $\Omega$ ]
$\mathcal{R}_0$	Wertetabelle für $\mathbf{R}_0$
$\mathbf{R}_{\{bp, bn\}}$	Stromschienenwiderstände [ $\Omega$ ]
$R_c$	Wärmewiderstand der Zellkerne [ $\text{K W}^{-1}$ ]
$\mathbf{R}_{\{cp, cn\}}$	Kontaktwiderstände [ $\Omega$ ]
$R_n$	Wärmewiderstände zwischen benachbarten Zellen [ $\text{K W}^{-1}$ ]
$R_p$	Widerstände der Zellenpolarisation [ $\Omega$ ]
$\mathcal{R}_p$	Wertetabelle für $\mathbf{R}_p$
$R_s$	Wärmewiderstände der Zelloberfläche [ $\text{K W}^{-1}$ ]
$R_\Sigma$	Summe aus $\mathbf{R}_0$ , $\mathbf{R}_{cp}$ und $\mathbf{R}_{cn}$ [ $\Omega$ ]
SOC	Ladezustand
SOH <sub>Q</sub>	Kapazitätsbasierter Alterungszustand der Zellen
SOH <sub>R</sub>	Widerstandsbasierter Alterungszustand der Zellen
$T_{\text{amb}}$	Umgebungstemperatur [K]
$T_c$	Temperatur der Zellkerne [K]

$T_s$	Temperatur der Zelloberflächen [K]
$U$	Hilfsmatrix des Modells, siehe (3.133)
$v_0$	Ohmscher Spannungsabfall der Zellen [V]
$v_p$	Polarisationsspannungen der RC-Glieder [V]
$v_{\text{pol}}$	Gesamtpolarisationsspannung [V]
$v_{\Sigma}$	Summe aus $E_m$ und $v_{\text{pol}}$ [V]
$v_{\text{ter}}$	Klemmenspannung der Zellen [V]
$W$	Hilfsmatrix des Modells, siehe (3.135)
$\Delta_X$	Parametervariation für die Variable $X$
$\eta_c$	Coulombsche Effizienz
$\sigma_X$	Parametervarianz für die Variable $X$
$\tau_{\{c,s,cs\}}$	Thermische Zeitkonstanten [s]
$\tau_p$	Zeitkonstanten der RC-Glieder [s]

## Datengetriebenes Zellmonitoring

$c$	Zählvariable für die Zellen
$C$	Kovarianzmatrix
$C_Q(\cdot)$	Beitrag zur $Q$ -Teststatistik
$C_{T^2}(\cdot)$	Beitrag zur $T^2$ -Teststatistik
DT	Detektionszeit [h]
$\mathbb{F}$	Merkmalsraum ( <i>Feature-Space</i> )
$\text{FAR}_{\text{test}}$	Fehlalarmrate im Test
$\text{FAR}_{\text{train}}$	Fehlalarmrate im Training
$\mathfrak{G}$	Gram-Matrix im Merkmalsraum $\mathbb{F}$
$i_{\text{ISC}}$	Kurzschlussstrom des internen Kurzschlusses [A]
$K$	Kernel-Matrix
$\tilde{K}$	Nicht-zentrierte Kernel-Matrix
$\hat{K}$	Approximation der Kernel-Matrix
$m$	Anzahl der Zellen
$\text{MDR}_{\Delta t}$	Rate der verpassten Fehler im Zeitraum $\Delta t$
$n$	Anzahl der Trainingsdaten nach optimaler Trainingsdatenwahl
$n_k$	Anzahl der Trainingsdaten, um die das Datenmodell der RPCA zum Zeitschritt $k$ ergänzt wird
$N$	Anzahl der Trainingsdaten
$N_k$	Anzahl der Trainingsdaten der RPCA zum Zeitschritt $k$
$\mathbf{p}_s$	$s$ -ter Eigenvektor von $\mathfrak{G}$
$\mathbf{p}_j$	$j$ -ter Eigenvektor ( $j$ -te Spalte von $P$ )

$\mathbf{P}$	Matrix, deren Spalten den Eigenvektoren von $\mathbf{C}$ entsprechen
$\mathbf{P}_{\text{pc}}$	Matrix, deren Spalten dem Hauptunterraum von $\mathbf{C}$ entsprechen
$\mathbf{P}_{\text{res}}$	Matrix, deren Spalten dem Residual-Unterraum von $\mathbf{C}$ entsprechen
$P_{\text{ISC}}$	Wärmegenerierung des internen Kurzschlusses [W]
$Q(\cdot)$	$Q$ -Teststatistik
$R_{\text{ISC}}$	Widerstand des internen Kurzschlusses [ $\Omega$ ]
$\mathbf{S}$	Diagonalmatrix mit den Standardabweichungen aller Zellen (RPCA), Matrix, deren Spalten den Eigenvektoren von $\frac{\mathbf{K}}{N-1}$ entsprechen (KPCA)
$\mathbf{S}_{\text{pc}}$	Matrix, deren Spalten dem Hauptunterraum von $\frac{\mathbf{K}}{N-1}$ entsprechen
$\mathbf{S}_{\text{res}}$	Matrix, deren Spalten dem Residual-Unterraum von $\frac{\mathbf{K}}{N-1}$ entsprechen
$\tau$	Zeitpunkt während des Trainings
$t$	Zeitpunkt während des Tests
$\mathbf{t}_t^{\text{pc}}$	Vektor der Projektionen in den Hauptunterraum zum Zeitpunkt $t$
$\mathbf{t}_t^{\text{res}}$	Vektor der Projektionen in den Residual-Unterraum zum Zeitpunkt $t$
$T^2(\cdot)$	$T^2$ -Teststatistik
$v_{\tau c}$	Spannung der $c$ -ten Zelle zum Zeitpunkt $\tau$ [V]
$\mathbf{v}_\tau$	Spannungsvektor aller Zellen zum Zeitpunkt $\tau$ [V]
$\mathbf{V}$	Spannungsmatrix aller Zellen (in Spalten) zu allen Zeitpunkten (in Zeilen) [V]
$x_{\tau c}$	Spannung der $c$ -ten Zelle zum Zeitpunkt $\tau$ nach der ORSS
$\mathbf{x}_\tau$	Spannungsvektor aller Zellen zum Zeitpunkt $\tau$ nach der ORSS
$\mathbf{X}$	Spannungsmatrix aller Zellen (in Spalten) zu allen Zeitpunkten (in Zeilen) nach der ORSS
$\mathfrak{z}$	Abbildung von $\mathbf{z}$ im Merkmalsraum $\mathbb{F}$
$z_{\tau c}$	Zentrierte Spannung der $c$ -ten Zelle zum Zeitpunkt $\tau$ nach der ORSS
$\mathbf{z}_\tau$	Zentrierter Spannungsvektor aller Zellen zum Zeitpunkt $\tau$ nach der ORSS
$\mathbf{Z}$	Zentrierte Spannungsmatrix aller Zellen (in Spalten) zu allen Zeitpunkten (in Zeilen) nach der ORSS
$\alpha$	Signifikanzniveau
$\boldsymbol{\alpha}_j$	$j$ -ter Eigenvektor von $\frac{\mathbf{K}}{N-1}$ ( $j$ -te Spalte von $\mathbf{S}$ )
$\beta$	Anzahl der Spalten von $\mathbf{P}_{\text{pc}}$
$\gamma$	Anzahl der Spalten von $\mathbf{S}_{\text{pc}}$
$\boldsymbol{\zeta}_c$	Zentrierter Spannungsvektor zu allen Zeitpunkten für die Zelle $c$ nach der ORSS
$\eta$	Vergessensfaktor (RPCA), Toleranz zur Approximation von $\widehat{\mathbf{K}}$ (KPCA)
$\kappa(\cdot, \cdot)$	Kernel-Funktion
$\lambda_j$	$j$ -ter Eigenwert
$\boldsymbol{\Lambda}$	Diagonalmatrix mit absteigend sortierten Eigenwerten $\lambda_j$
$\boldsymbol{\Lambda}_{\text{pc}}$	Diagonalmatrix mit den zu $\mathbf{P}_{\text{pc}}$ gehörenden Eigenwerten
$\boldsymbol{\Lambda}_{\text{res}}$	Diagonalmatrix mit den zu $\mathbf{P}_{\text{res}}$ gehörenden Eigenwerten

$\xi_c$	Spannungsvektor zu allen Zeitpunkten für die Zelle $c$ nach der ORSS
$\sigma$	Breite des Gaußkerns
$\Phi(\cdot)$	Abbildung in den Merkmalsraum $\mathbb{F}$
$\omega_{\text{gauss}}$	Anteil des Gauß-Kerns an der gemischten Kernel-Funktion
$\omega_{\text{lin}}$	Anteil des linearen Kerns an der gemischten Kernel-Funktion

## Aktive modellbasierte Fehlerdiagnose

$a_k$	Schalterstellung zum Zeitschritt $k$ (Aktion $a_k$ )
$a_{j,k+1}$	$j$ -te mögliche Schalterstellung (Aktion $a_{j,k+1}$ ) für den Zeitschritt $k + 1$
$\mathbb{A}$	Menge aller Aktionen
$\mathbb{B}$	Menge aller Bedingungen
$\mathbf{d}_k$	Messvektor zum Zeitschritt $k$
$\mathcal{D}_i$	Detektierbarkeitsmaß für den Fehler $f_i$
$\mathbf{D}_{k k-1}$	Angereicherte Messmatrix (Messgleichung und weiche Beschränkung) zum Zeitschritt $k$
$e_i$	$i$ -te Gleichung
$e_{f_i}$	Gleichung mit dem Fehler $f_i$
$e_{\text{aux},x_i}$	Hilfsgleichung für die Variable $x_i$ , $e_{\text{aux},x_i} : x_i = \bar{x}_i$
$\mathbb{E}$	Menge aller Gleichungen
$f_i$	$i$ -ter Fehler
$\hat{f}_i$	Geschätzte Amplitude des Fehlers $f_i$
$f\_X$	Fehler in der Komponente $X$
$F_{\chi_n^2, \lambda}$	Kumulative Verteilungsfunktion der nicht-zentralen $\chi^2$ -Verteilung mit $n$ Freiheitsgraden und dem Offset-Parameter $\lambda$
$g_{M,i}$	Summe quadrierter Residuen $r_i$ über ein Zeitfenster der Länge $M$
$\mathcal{H}_i$	Hypothese zum Fehler $f_i$
$\mathcal{H}_0$	Null-Hypothese: Hypothese für den fehlerfreien Fall
$\mathbb{H}$	Menge aller Hypothesen
$\hat{i}_{\text{act,off},i}$	Leckstrom des Aktiv-Schalters im Fehlerfall
$\hat{i}_{\text{byp,off},i}$	Leckstrom des Bypass-Schalters im Fehlerfall
$i_{\text{ter}}$	Klemmenstrom der RBS-Zelle
$\bar{k}$	bekannte Variable $k$
$\mathbb{K}$	Menge aller bekannten Variablen
$\mathbf{K}_k$	Kalman-Gain-Matrix zum Zeitschritt $k$
$L$	Kosten einer Fehlentscheidung für die Fehlerisolation
$\mathbb{M}$	(Teil-)Menge an Gleichungen (Modell)
$\mathbb{M}^+$	PSO-Teil der Menge $\mathbb{M}$

$n_{\mathbb{E}}$	Anzahl der Gleichungen
$n_{\mathbb{K}}$	Anzahl bekannter Variablen
$n_{\mathbb{V}}$	Anzahl unbekannter Variablen
$N_{\theta}$	Länge des Parametervektors $\theta$
$P(H_i \Phi_k)$	Konfidenz, dass der Fehler $f_i$ im Messraum $\Phi_k$ existiert
$P_e$	Wahrscheinlichkeit einer falschen Hypothesen-Deklaration
$\hat{P}_i$	Wahrscheinlichkeit der Hypothese $\mathcal{H}_i$ basierend auf allen Messräumen $\Phi_k$ bis zum Zeitschritt $k$
$P_k$	Kovarianzmatrix des geschätzten Parametervektors $\hat{\theta}_k$ zum Zeitschritt $k$
$P_{\hat{d}_k, \hat{d}_k}$	Kovarianzmatrix des geschätzten Messvektors $\hat{d}_k$
$P_{\hat{\theta}_k, \hat{d}_k}$	Korrelationsmatrix von geschätztem Parametervektor $\hat{\theta}_k$ und Messvektor $\hat{d}_k$
$r$	Residuenvektor
$r_i$	$i$ -tes Residuum
$R_{\text{act}}$	Widerstand des Aktiv-Schalters: $R_{\text{act,on}}$ im geschlossenen und $R_{\text{act,off}}$ im offenen Zustand
$R_{\text{byp}}$	Widerstand des Bypass-Schalters: $R_{\text{byp,on}}$ im geschlossenen und $R_{\text{byp,off}}$ im offenen Zustand
$s$	Schaltzustand
s-rang( $\mathbf{A}$ )	Struktureller Rang der Matrix $\mathbf{A}$
$S_{f_i}$	Sensitivität der Residuen auf den Fehler $f_i$
$v_{\text{byp}}$	Spannung über dem Bypass-Schalter
$v_{\text{ter}}$	Klemmenspannung der RBS-Zelle
$\mathbb{V}$	Menge aller unbekanntenen Variablen
$\mathbf{W}_{k k-1}$	Matrix mit Sigma-Punkten zum Zeitschritt $k$
$\hat{x}$	Schätzung von $x$
$\mathbf{y}$	Messvektor
$\theta_k$	Parametervektor zum Zeitpunkt $k$
$\mu_i^{(a_k)}$	Richtung des Residuenvektors für die Aktion $a_k$ im Falle $\mathcal{H}_i = \text{wahr}$
$\bar{\mu}_i^{(a_k)}$	Richtung des Residuenvektors für die Aktion $a_k$ im Falle $\mathcal{H}_i = \text{falsch}$
$\pi$	Strategie zur Auswahl der nächsten, besten Aktion
$\rho_{\xi}(x)$	Wahrscheinlichkeitsdichtefunktion von $\xi$ an der Stelle $x$
$\rho_i^{(a)}$	Wahrscheinlichkeitsdichtefunktion der Residuen/Messwerte, wenn Hypothese $\mathcal{H}_i$ unter Aktion $a$ wahr ist
$\sigma_{\xi}^2$	Varianz der Zufallsvariablen $\xi$
$\Sigma_{\xi}$	Kovarianzmatrix der Zufallsvariablen $\xi$
$\Sigma_{\theta,k}$	Varianz des Parametervektors $\theta_k$ zum Zeitpunkt $k$
$\varphi(\mathbb{M})$	Analytische Redundanz des Modells $\mathbb{M}$
$\varphi_s(\mathbb{M})$	Strukturelle Redundanz des Modells $\mathbb{M}$

---

$\Phi_k$	Messraum nach Aktion $a_k$
$\Phi_s$	Messraum während des Schaltzustands $s$
$\chi_{n,\lambda}^2$	Wahrscheinlichkeitsdichtefunktion einer nicht-zentralen $\chi^2$ -Verteilung mit $n$ Freiheitsgraden und dem Offset-Parameter $\lambda$
<code>script</code>	Platzhalter in einem Algorithmus für ein Skript (Pseudocode)
<code>[a]=func(b)</code>	Funktionsaufruf in einem Algorithmus mit dem Eingang $b$ und dem Ausgang $a$ (Pseudocode)



# Abbildungsverzeichnis

2.1	Prinzipieller Aufbau und Funktionsweise einer Lithium-Ionen-Zelle . . . . .	14
2.2	Bauformen und Zellformate von Lithium-Ionen-Batterien . . . . .	17
2.3	Rekonfigurierbare Batteriezelle in normaler und in Halbbrückendarstellung .	21
2.4	Kapazitätstest einer SMG-Zelle bei unterschiedlichen Temperaturen. . . . .	23
2.5	Test zur Ermittlung der POCV einer SMG-Zelle . . . . .	24
2.6	Vergleich der POCV-Methode und der schrittweisen Entladung zur Ermittlung der Ruhespannungskennlinie . . . . .	26
2.7	Nyquist- und Bode-Diagramm einer PAN-Zelle bei einer Temperatur von 5 °C und einem Ladezustand von 10 % . . . . .	29
2.8	Nyquist- und Bode-Diagramme bei einer Veränderung des Ladezustands und der Temperatur . . . . .	30
2.9	HPPC-Test zur Parameteridentifikation . . . . .	31
2.10	Vergrößerter Ausschnitt eines Pulses aus dem HPPC-Testprofil mit Zuordnung eines elektronischen Ersatzschaltbilds . . . . .	32
2.11	Dynamische Entladung mit einem WLTP-basierten Stromprofil . . . . .	33
2.12	Konstantstrom-Entladung und -Ladung . . . . .	34
2.13	Entstehung und Auslöser interner Kurzschlüsse in Lithium-Ionen-Batterien .	36
2.14	Effekte eines internen Kurzschlusses . . . . .	37
2.15	Vollständige, ökonomische und reduzierte Singulärwertzerlegung . . . . .	40
2.16	Mittelwert und Hauptkomponenten normalverteilter Stichproben . . . . .	42
2.17	Vergleich der euklidischen mit der Mahalanobis-Distanz . . . . .	44
2.18	Zwei exemplarische Cluster zur Demonstration der PCA und KPCA . . . . .	46
2.19	Projektion der Cluster aus Abbildung 2.18 mithilfe der PCA und der KPCA	46
2.20	Visualisierung des zusätzlichen Freiheitsgrads durch die nichtlineare Abbildung in einen höherdimensionalen Raum . . . . .	47
2.21	Kerndichteschätzer mit einem Normalkern als Kernfunktion für verschiedene Bandbreiten . . . . .	48
2.22	Zusammenfassung des zweischrittigen Prinzips für das lineare Kalman-Filter	53
3.1	Typische elektrische Ersatzschaltbildmodelle für Fahrzeugbatterien . . . . .	59
3.2	Thermische Zellmodelle, die für die Echtzeitmodellierung geeignet sind . . . .	64
3.3	Übersicht des gesamten Modell-Frameworks . . . . .	70

3.4	Ersatzschaltbild der elektrischen Verschaltung von vier Zellen . . . . .	71
3.5	Elektrische Ersatzschaltbilddarstellung des Temperaturverteilungsmodells . .	74
3.6	Parameter eines DP-Modells für die PAN-Zelle . . . . .	80
3.7	Parameter eines DP-Modells für die SMG-Zelle . . . . .	81
3.8	Validierung der identifizierten Parameter . . . . .	82
3.9	Box-Plot des Spannungsfehlers während der gesamten Simulation . . . . .	84
3.10	Validierung des Modell-Frameworks am Fehlerfall ICR . . . . .	86
3.11	Validierung des Modell-Frameworks am Fehlerfall ESC . . . . .	88
3.12	Validierung des Modell-Frameworks am Fehlerfall ISC . . . . .	89
3.13	Exemplarische Darstellung der zellindividuellen, internen Zustände . . . . .	91
4.1	Unterscheidung kleinerer und größerer ISCs sowie Soft- und Hard-ISCs . . .	100
4.2	Anfangs-, mittlere und Endphase eines ISCs . . . . .	101
4.3	Ermittelte Innenwiderstände der PAN-Zellen . . . . .	102
4.4	Schematischer Aufbau des Prüfstands und des PAN-Moduls . . . . .	103
4.5	Mechanischer Aufbau des PAN-Moduls und Modulverspannung . . . . .	104
4.6	Gemessene Zellspannungen für den Fall $R_{ISC} = 100 \Omega$ . . . . .	105
4.7	Spannungsdifferenzen der PAN-Zellen bezogen auf die Median-Zelle . . . . .	106
4.8	Box-Plots des RMSEs aller 12 PAN-Zellen untereinander . . . . .	107
4.9	Schematischer und mechanischer Aufbau des SMG-Moduls . . . . .	108
4.10	Ermittelte Innenwiderstände der SMG-Zellen . . . . .	109
4.11	Spannungsdifferenzen der SMG-Zellen bezogen auf die Median-Zelle . . . . .	111
4.12	Box-Plots des RMSEs aller 12 SMG-Zellen untereinander . . . . .	112
4.13	Einzelzellspannungen und Spannungsdifferenzen der PHEV-Zellen . . . . .	113
4.14	Box-Plot des RMSEs aller 104 PHEV-Zellen untereinander . . . . .	113
4.15	Zellkapazitäten im Modell . . . . .	114
4.16	Innenwiderstände im Modell . . . . .	115
4.17	Einzelzellspannungen und Spannungsdifferenzen im Modell . . . . .	116
4.18	Eingangsdaten, basierend auf den Zellspannungen des SMG-Moduls . . . . .	120
4.19	Eingangsdaten, basierend auf den Zellspannungen des PAN-Moduls . . . . .	121
4.20	Kontrollstatistiken des linearen Monitorings für den MDL-Datensatz mit $R_{ISC} = 10 \Omega$ . . . . .	125
4.21	Beitragsdiagramme nach Auftreten des $10 \Omega$ -ISCs für den MDL-Datensatz .	128
4.22	Zellkapazitäten zu Beginn und zum Ende einer beschleunigten Alterungssimu- lation . . . . .	129
4.23	Kontrollstatistiken des PCA-Monitorings während einer beschleunigten Alte- rungssimulation . . . . .	129
4.24	Kontrollstatistiken des RPCA-Monitorings während einer beschleunigten Al- terungssimulation . . . . .	134

4.25	Kontrollstatistiken des MWPCA-Monitorings während einer beschleunigten Alterungssimulation . . . . .	135
4.26	Kontrollstatistiken nach Anwendung des linearen PCA-Monitorings mit unterschiedlichen Anregungen im Training und Test . . . . .	136
4.27	Übersicht aller Schritte des KPCA-basierten Zellmonitorings zur ISC-Detektion	138
4.28	Häufig eingesetzte Kernel-Funktionen . . . . .	144
4.29	Konturlinien der ersten Kernel-Hauptkomponenten . . . . .	148
4.30	Konturdarstellung der Kontrollstatistiken in der $\zeta_{10}\zeta_{11}$ -Ebene . . . . .	150
4.31	Konturdarstellung der Kontrollstatistiken in der $\zeta_6\zeta_{10}$ -Ebene . . . . .	151
4.32	Ergebnisse für den Fall $R_{ISC} = 10 \Omega$ mit der linearen Kernel-Funktion $\kappa_{lin}$ . .	154
4.33	Ergebnisse für den Fall $R_{ISC} = 10 \Omega$ mit der gemischten Kernel-Funktion $\kappa_{mix}$	155
4.34	Ergebnisse für den Fall $R_{ISC} = 100 \Omega$ mit der linearen Kernel-Funktion $\kappa_{lin}$ .	155
4.35	Ergebnisse für den Fall $R_{ISC} = 100 \Omega$ mit der gemischten Kernel-Funktion $\kappa_{mix}$	156
4.37	Vom Algorithmus 4.1 ausgewählte Spalten der Kernel-Matrix . . . . .	163
4.38	Approximation des Merkmalraums $\mathbb{F}$ basierend auf der unvollständigen Cholesky-Zerlegung. . . . .	164
4.39	Konturdarstellung der Kontrollstatistiken basierend auf der vollständigen Datenmatrix und der Approximation . . . . .	165
4.40	Abnahme der Summe der Diagonalelemente von $\mathbf{G}$ . . . . .	166
4.41	Resultierende FAR im Training bei einer Variation der Parameter . . . . .	168
4.42	Resultierende FAR im Test bei einer Variation der Parameter . . . . .	168
4.43	Resultierende MDR bei einer Variation der Parameter . . . . .	169
4.44	MDR und FAR im Test bei einer Variation der Parameter . . . . .	169
4.45	Resultierende Kontrollstatistiken für den fehlerfreien SMG-Datensatz . . . .	174
4.46	Beitragsdiagramme im Falle der fehlerfreien SMG-Zellen . . . . .	174
4.47	Resultierende Kontrollstatistiken für den SMG-Datensatz mit $R_{ISC} = 10 \Omega$ .	175
4.48	Beitragsdiagramme für die SMG-Zellen mit $R_{ISC} = 10 \Omega$ . . . . .	175
4.49	Resultierende Kontrollstatistiken für den SMG-Datensatz mit $R_{ISC} = 100 \Omega$ .	176
4.50	Beitragsdiagramme für die SMG-Zellen mit $R_{ISC} = 100 \Omega$ . . . . .	176
4.51	Resultierende Kontrollstatistiken für den SMG-Datensatz mit $R_{ISC} = 1 \text{ k}\Omega$ .	177
4.52	Beitragsdiagramme für die SMG-Zellen mit $R_{ISC} = 1 \text{ k}\Omega$ . . . . .	177
4.53	Resultierende Kontrollstatistiken für den SMG-Datensatz mit $R_{ISC} = 10 \text{ k}\Omega$ .	178
4.54	Beitragsdiagramme für die SMG-Zellen mit $R_{ISC} = 10 \text{ k}\Omega$ . . . . .	178
5.1	1-RC-Thevenin-Modell einer RBS-Zelle mit einem AS und einem BS . . . . .	187
5.2	Elektrische Verbindung von sechs RBS-Zellen (2s3p-Konfiguration) . . . . .	187
5.3	Thermisches Cauer-Modell zweiter Ordnung . . . . .	188
5.4	Strukturelle Isolierbarkeitsanalyse eines 2s3p-Batteriemoduls . . . . .	192

5.5	Visualisierung der Schritte des Greedy-Algorithmus zum Finden der MSO-Teilsysteme mit den wenigsten Gleichungen . . . . .	201
5.6	MSO-Teilsysteme mit der geringsten Anzahl von Gleichungen für jeden Fehler	203
5.7	Experimenteller Aufbau des RBS-Moduls . . . . .	205
5.8	Experimentelle Ergebnisse für den emulierten Fehler $f_{\hat{i}_{\text{byp,off},2}}$ . . . . .	206
5.9	Komplexitätsanalyse: Vom Algorithmus benötigte Schritte zur Berechnung der MSO-Sets . . . . .	208
5.10	Framework zur aktiven Fehlerdiagnose . . . . .	214
5.11	Verteilung der quadrierten Residuenvektornorm im fehlerfreien und im fehlerhaften Fall . . . . .	216
5.12	Abbildungen zum Beispiel 5.2: Richtung der Residuenvektoren . . . . .	221
5.13	WLTP-basiertes Stromprofil . . . . .	222
5.14	Fehler-Isolierbarkeitsmatrix des 2s3p-Batteriemoduls . . . . .	223
5.15	Experimentelle Ergebnisse des beschränkten Parameter-Schätzers . . . . .	225
5.16	Ersatzschaltbild der zweiten Reihe des Versuchsaufbaus aus Abbildung 5.7 .	227
5.17	Experimentelle Ergebnisse für die Diagnose von $f_{E_{m,6}}$ . . . . .	228
5.18	Ersatzschaltbild der ersten Reihe des Versuchsaufbaus aus Abbildung 5.7 . .	230
5.19	Experimentelle Ergebnisse für die Diagnose von $f_{R_{\text{con},2}}$ . . . . .	231
5.20	Experimentelle Ergebnisse für den Fehler $f_{R_{\text{con},2}}$ . . . . .	232
A.1	Kapazitätstest bei unterschiedlichen Temperaturen. . . . .	241
A.2	Test zur Ermittlung der POCV . . . . .	242
A.3	HPPC-Test zur Parameteridentifikation . . . . .	242
A.4	Dynamische Entladung mit einem WLTP-basierten Stromprofil . . . . .	243
A.5	Konstantstromentladung und -ladung . . . . .	243
A.6	Graphische Oberfläche des Modell-Frameworks . . . . .	244

# Tabellenverzeichnis

1.1	Übersicht modellbasierter Methoden . . . . .	4
1.2	Übersicht wissensbasierter Methoden . . . . .	5
1.3	Übersicht datengetriebener Methoden . . . . .	6
2.1	Spezifikationen der verwendeten Batteriezellentypen . . . . .	22
3.1	Parametrierung des Alterungsmodells . . . . .	68
3.2	Resultierender Modellfehler für verschiedene Temperaturen . . . . .	83
3.3	Parameter des thermischen Modells und des Temperaturverteilungsmodells . . . . .	83
3.4	Experimentell ermittelte Parametervariation der verwendeten Zellen . . . . .	83
3.5	Kontaktwiderstände für verschiedene Verbindungstechniken und deren Variation . . . . .	84
3.6	Simulationsergebnisse für die drei Fehlerfälle ICR, ESC und ISC . . . . .	85
3.7	Simulationszeiten eines 100s5p-Batteriesystems . . . . .	90
4.1	Ermittelte Zellkapazitäten der 12 PAN-Zellen . . . . .	102
4.2	Ermittelte Zellkapazitäten der 12 SMG-Zellen . . . . .	109
4.3	Übersicht und Vergleich der Datengrundlage . . . . .	117
4.4	Zusammenfassung der Ergebnisse des KPCA-basierten Monitorings . . . . .	153
4.5	Vergleich der Detektionszeiten mit bekannten Methoden aus der Literatur . . . . .	157
4.6	Partielle Ableitungen der Kernel-Funktionen . . . . .	173
5.1	Modellgleichungen für das RBS-Modul . . . . .	190
5.2	Gespeicherte Daten des Algorithmus nach Schritt 1 . . . . .	200
5.3	Gespeicherte Daten des Algorithmus nach Schritt 2 . . . . .	202
5.4	Beschreibung der Komponenten des Versuchsaufbaus in Abbildung 5.7 . . . . .	205
5.5	Rauschwerte für die Simulationen und die experimentelle Validierung . . . . .	222
5.6	Minimal detektierbare Fehleramplituden . . . . .	224
5.7	Initiale Parameter zu Beginn des Lernprozesses . . . . .	226



# Literatur

- [1] H. Abdi und L. J. Williams. „Principal component analysis“. In: *Wiley Interdisciplinary Reviews: Computational Statistics* 2.4 (2010), S. 433–459. DOI: 10.1002/wics.101.
- [2] S. M. M. Alavi, M. F. Samadi und M. Saif. „Plating Mechanism Detection in Lithium-ion batteries, by using a particle-filtering based estimation technique“. In: *2013 American Control Conference (ACC 2013)*. Piscataway, NJ: IEEE, 2013, S. 4356–4361. DOI: 10.1109/ACC.2013.6580510.
- [3] S. Altmannshofer, C. Endisch, J. Martin, M. Gerngross und R. Limbacher. „Robust estimation of vehicle longitudinal dynamics parameters“. In: *2016 IEEE Intelligent Vehicles Symposium (IV)*. Piscataway, NJ, 2016, S. 566–571. DOI: 10.1109/IVS.2016.7535443.
- [4] D. Andrea. *Battery management systems for large lithium-ion battery packs*. Boston: Artech House, 2010.
- [5] T. Arens, F. Hettlich, C. Karpfinger, U. Kockelkorn, K. Lichtenegger und H. Stachel. *Mathematik*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2015. DOI: 10.1007/978-3-642-44919-2.
- [6] J. Armengol, A. Bregon, T. Escobet, E. Gelso, M. Krysander, M. Nyberg, X. Olive, B. Pulido und L. Travé-Massuyès. „Minimal Structurally Overdetermined sets for residual generation: A comparison of alternative approaches“. In: *IFAC Proceedings Volumes* 42.8 (2009), S. 1480–1485. DOI: 10.3182/20090630-4-ES-2003.00241.
- [7] K. Asakura, M. Shimomura und T. Shodai. „Study of life evaluation methods for Li-ion batteries for backup applications“. In: *Journal of Power Sources* 119-121 (2003), S. 902–905. DOI: 10.1016/S0378-7753(03)00208-8.
- [8] F. R. Bach und M. I. Jordan. „Kernel Independent Component Analysis“. In: *Journal of machine learning research* 3 (2003), S. 1–48. DOI: 10.1162/153244303768966085.
- [9] F. Bahiraei, M. Ghalkhani, A. Fartaj und G.-A. Nazri. „A pseudo 3D electrochemical-thermal modeling and analysis of a lithium-ion battery for electric vehicle thermal management applications“. In: *Applied Thermal Engineering* 125 (2017), S. 904–918. DOI: 10.1016/j.applthermaleng.2017.07.060.
- [10] A. Barré, B. Deguilhem, S. Grolleau, M. Gérard, F. Suard und D. Riu. „A review on lithium-ion battery ageing mechanisms and estimations for automotive applications“. In: *Journal of Power Sources* 241 (2013), S. 680–689. DOI: 10.1016/j.jpowsour.2013.05.040.
- [11] G. Baudat und F. Anouar. „Kernel-based methods and function approximation“. In: *IJCNN'01*. Piscataway, N.J: IEEE, 2001, S. 1244–1249. DOI: 10.1109/IJCNN.2001.939539.
- [12] M. Baumann, L. Wildfeuer, S. Rohr und M. Lienkamp. „Parameter variations within Li-Ion battery packs – Theoretical investigations and experimental quantification“. In: *Journal of Energy Storage* 18 (2018), S. 295–307. DOI: 10.1016/j.est.2018.04.031.
- [13] V. A. Bavdekar, A. P. Deshpande und S. C. Patwardhan. „Identification of process and measurement noise covariance for state and parameter estimation using extended Kalman filter“. In: *Journal of Process Control* 21.4 (2011), S. 585–601. DOI: 10.1016/j.jprocont.2011.01.001.

- [14] R. Bellmann. „Combinatorial processes and dynamic programming“. In: *Proceedings of the Tenth Symposium in Applied Mathematics of The American Mathematical Society* (1958).
- [15] J. C. Bezdek, R. Ehrlich und W. Full. „FCM: The fuzzy c-means clustering algorithm“. In: *Computers & Geosciences* 10.2-3 (1984), S. 191–203. DOI: 10.1016/0098-3004(84)90020-7.
- [16] C. R. Birkl, M. R. Roberts, E. McTurk, P. G. Bruce und D. A. Howey. „Degradation diagnostics for lithium ion cells“. In: *Journal of Power Sources* 341 (2017), S. 373–386. DOI: 10.1016/j.jpowsour.2016.12.011.
- [17] M. Blanke, M. Kinnaert, J. Lunze und M. Staroswiecki. *Diagnosis and Fault-Tolerant Control*. Berlin, Heidelberg: Springer, 2016. DOI: 10.1007/978-3-662-47943-8.
- [18] I. Bloom, J. Christophersen und K. Gering. „Differential voltage analyses of high-power lithium-ion cells“. In: *Journal of Power Sources* 139.1-2 (2005), S. 304–313. DOI: 10.1016/j.jpowsour.2004.07.022.
- [19] N. Bouchhima, M. Gossen, S. Schulte und K. P. Birke. „Lifetime of self-reconfigurable batteries compared with conventional batteries“. In: *Journal of Energy Storage* 15 (2018), S. 400–407. DOI: 10.1016/j.est.2017.11.014.
- [20] N. Bouchhima, M. Schnierle, S. Schulte und K. P. Birke. „Active model-based balancing strategy for self-reconfigurable batteries“. In: *Journal of Power Sources* 322 (2016), S. 129–137. DOI: 10.1016/j.jpowsour.2016.05.027.
- [21] N. Bouchhima, M. Schnierle, S. Schulte und K. P. Birke. „Optimal energy management strategy for self-reconfigurable batteries“. In: *Energy* 122 (2017), S. 560–569. DOI: 10.1016/j.energy.2017.01.043.
- [22] M. J. Brand, M. H. Hofmann, M. Steinhardt, S. F. Schuster und A. Jossen. „Current distribution within parallel-connected battery cells“. In: *Journal of Power Sources* 334 (2016), S. 202–212. DOI: 10.1016/j.jpowsour.2016.10.010.
- [23] T. Bruen und J. Marco. „Modelling and experimental evaluation of parallel connected lithium ion cells for an electric vehicle battery system“. In: *Journal of Power Sources* 310 (2016), S. 91–101. DOI: 10.1016/j.jpowsour.2016.01.001.
- [24] S. L. Brunton und J. N. Kutz. *Data-Driven Science and Engineering: Machine learning, dynamical systems and control*. Cambridge University Press, 2019. DOI: 10.1017/9781108380690.
- [25] J. R. Bunch, C. P. Nielsen und D. C. Sorensen. „Rank-one modification of the symmetric eigenproblem“. In: *Numerische Mathematik* 31.1 (1978), S. 31–48. DOI: 10.1007/BF01396012.
- [26] M. Charkhgard und M. Farrokhi. „State-of-Charge Estimation for Lithium-Ion Batteries Using Neural Networks and EKF“. In: *IEEE Transactions on Industrial Electronics* 57.12 (2010), S. 4178–4187. DOI: 10.1109/TIE.2010.2043035.
- [27] A. Chen, H. Zhou, Y. An und W. Sun. „PCA and PLS monitoring approaches for fault detection of wastewater treatment process“. In: *Proceedings, 2016 IEEE 25th International Symposium on Industrial Electronics (ISIE)*. Piscataway, NJ: IEEE, 2016, S. 1022–1027. DOI: 10.1109/ISIE.2016.7745032.
- [28] M. Chen und G. A. Rincon-Mora. „Accurate Electrical Battery Model Capable of Predicting Runtime and I–V Performance“. In: *IEEE Transactions on Energy Conversion* 21.2 (2006), S. 504–511. DOI: 10.1109/TEC.2006.874229.



- [29] W. Chen, W.-T. Chen, M. Saif, M.-F. Li und H. Wu. „Simultaneous Fault Isolation and Estimation of Lithium-Ion Batteries via Synthesized Design of Luenberger and Learning Observers“. In: *IEEE Transactions on Control Systems Technology* 22.1 (2014), S. 290–298. DOI: 10.1109/TCST.2013.2239296.
- [30] Z. Chen. „Bayesian Filtering: From Kalman Filters to Particle Filters, and Beyond“. In: *Statistics: A Journal of Theoretical and Applied Statistics* 182 (2003). DOI: 10.1080/02331880309257.
- [31] Z. Chen, F. Lin, C. Wang, Y. Le Wang und M. Xu. „Active Diagnosability of Discrete Event Systems and its Application to Battery Fault Diagnosis“. In: *IEEE Transactions on Control Systems Technology* 22.5 (2014), S. 1892–1898. DOI: 10.1109/TCST.2013.2291069.
- [32] Z. Chen, K. Xu, J. Wei und G. Dong. „Voltage fault detection for lithium-ion battery pack using local outlier factor“. In: *Measurement* (2019). DOI: 10.1016/j.measurement.2019.06.052.
- [33] L. Cheng, C. Ke, S. Fengchun, T. Peng und Z. Hongwei. „Research on thermo-physical properties identification and thermal analysis of EV Li-ion battery“. In: *IEEE Vehicle Power and Propulsion Conference, 2009*. Piscataway, NJ: IEEE, 2009, S. 1643–1648. DOI: 10.1109/VPPC.2009.5289653.
- [34] H. Chernoff. „Sequential Design of Experiments“. In: *The Annals of Mathematical Statistics* 30.3 (1959), S. 345–360. DOI: 10.1007/978-1-4612-4380-9\_27.
- [35] E. Chow und A. Willsky. „Analytical redundancy and the design of robust failure detection systems“. In: *IEEE Transactions on Automatic Control* 29.7 (1984), S. 603–614. DOI: 10.1109/TAC.1984.1103593.
- [36] Z. Chu, G. L. Plett, M. S. Trimboli und M. Ouyang. „A control-oriented electrochemical model for lithium-ion battery, Part I: Lumped-parameter reduced-order model with constant phase element“. In: *Journal of Energy Storage* 25 (2019), S. 100828. DOI: 10.1016/j.est.2019.100828.
- [37] S. Ci, N. Lin und D. Wu. „Reconfigurable Battery Techniques and Systems: A Survey“. In: *IEEE Access* 4 (2016), S. 1175–1189. DOI: 10.1109/ACCESS.2016.2545338.
- [38] S. Ci, J. Zhang, H. Sharif und M. Alahmad. „Dynamic reconfigurable multi-cell battery: A novel approach to improve battery performance“. In: *Twenty-Seventh Annual IEEE Applied Power Electronics Conference and Exposition (APEC)*. Piscataway, NJ, 2012, S. 439–442. DOI: 10.1109/APEC.2012.6165857.
- [39] D. Cittanti, A. Ferraris, A. Airale, S. Fiorot, S. Scavuzzo und M. Carello. „Modeling Li-ion batteries for automotive application: A trade-off between accuracy and complexity“. In: *2017 International Conference of Electrical and Electronic Technologies for Automotive*. Piscataway, NJ: IEEE, 2017, S. 1–8. DOI: 10.23919/EETA.2017.7993213.
- [40] K. Cohen und Q. Zhao. „Active Hypothesis Testing for Anomaly Detection“. In: *IEEE Transactions on Information Theory* 61.3 (2015), S. 1432–1450. DOI: 10.1109/TIT.2014.2387857.
- [41] A. Cordoba-Arenas, S. Onori, Y. Guezennec und G. Rizzoni. „Capacity and power fade cycle-life model for plug-in hybrid electric vehicle lithium-ion battery cells containing blended spinel and layered-oxide positive electrodes“. In: *Journal of Power Sources* 278 (2015), S. 473–483. DOI: 10.1016/j.jpowsour.2014.12.047.
- [42] A. Cordoba-Arenas, S. Onori und G. Rizzoni. „A control-oriented lithium-ion battery pack model for plug-in hybrid electric vehicle cycle-life studies and system design with consideration of health management“. In: *Journal of Power Sources* 279 (2015), S. 791–808. DOI: 10.1016/j.jpowsour.2014.12.048.

- [43] T. H. Cormen. *Introduction to algorithms*. 2. Edition, 6. Druck. Cambridge, Massachusetts und Boston, Massachusetts: MIT Press und McGraw-Hill, 2005.
- [44] L. D. Couto und M. Kinnaert. „Internal and Sensor Fault Detection and Isolation for Li-ion Batteries“. In: *IFAC-PapersOnLine* 51.24 (2018), S. 1431–1438. DOI: 10.1016/j.ifacol.2018.09.536.
- [45] N. Cristianini und J. Shawe-Taylor. *An introduction to support vector machines: And other kernel-based learning methods*. Cambridge und New York: Cambridge University Press, 2000. DOI: 10.1017/CB09780511801389.
- [46] S. D’Arco, L. Piegari und P. Tricoli. „A modular converter with embedded battery cell balancing for electric vehicles“. In: *Electrical systems for aircraft, railway and ship propulsion (ESARS), 2012*. Piscataway, NJ: IEEE, 2012, S. 1–6. DOI: 10.1109/ESARS.2012.6387499.
- [47] S. D’Arco, L. Piegari und P. Tricoli. „Power and balancing control considerations on modular multilevel converters for battery electric vehicles“. In: *Power Electronics and Applications (EPE), 2013 15th European Conference on*. [Piscataway, N.J.]: [IEEE], 2013, S. 1–9. DOI: 10.1109/EPE.2013.6634386.
- [48] Da Li, Z. Zhang, P. Liu, Z. Wang und L. Zhang. „Battery Fault Diagnosis for Electric Vehicles Based on Voltage Abnormality by Combining the Long Short-Term Memory Neural Network and the Equivalent Circuit Model“. In: *IEEE Transactions on Power Electronics* 36.2 (2021), S. 1303–1315. DOI: 10.1109/TPEL.2020.3008194.
- [49] N. Damay, C. Forgez, M.-P. Bichat und G. Friedrich. „Thermal modeling of large prismatic LiFePO<sub>4</sub>/graphite battery. Coupled thermal and heat generation models for characterization and simulation“. In: *Journal of Power Sources* 283 (2015), S. 37–45. DOI: 10.1016/j.jpowsour.2015.02.091.
- [50] X. Deng und X. Tian. „A new fault isolation method based on unified contribution plots“. In: *Proceedings of the 30th Chinese Control Conference* (2011), S. 4280–4285.
- [51] S. Dey, Z. A. Biron, S. Tatipamula, N. Das, S. Mohon, B. Ayalew und P. Pisu. „Model-based real-time thermal fault diagnosis of Lithium-ion batteries“. In: *Control Engineering Practice* 56 (2016), S. 37–48. DOI: 10.1016/j.conengprac.2016.08.002.
- [52] S. Dey, Z. A. Biron, S. Tatipamula, N. Das, S. Mohon, B. Ayalew und P. Pisu. „On-board Thermal Fault Diagnosis of Lithium-ion Batteries For Hybrid Electric Vehicle Application“. In: *IFAC-PapersOnLine* 48.15 (2015), S. 389–394. DOI: 10.1016/j.ifacol.2015.10.056.
- [53] S. Dey, S. Mohon, P. Pisu und B. Ayalew. „Sensor Fault Detection, Isolation, and Estimation in Lithium-Ion Batteries“. In: *IEEE Transactions on Control Systems Technology* 24.6 (2016), S. 2141–2149. DOI: 10.1109/TCST.2016.2538200.
- [54] S. Dey, H. E. Perez und S. J. Moura. „Model-Based Battery Thermal Fault Diagnostics: Algorithms, Analysis, and Experiments“. In: *IEEE Transactions on Control Systems Technology* 27.2 (2019), S. 576–587. DOI: 10.1109/TCST.2017.2776218.
- [55] D. Di Domenico, G. Fiengo und A. Stefanopoulou. „Lithium-ion battery state of charge estimation with a Kalman Filter based on a electrochemical model“. In: *IEEE Multi-Conference on Systems and Control (MSC)* (2008), S. 702–707. DOI: 10.1109/CCA.2008.4629639.
- [56] W. Diao, I. H. Naqvi und M. Pecht. „Early detection of anomalous degradation behavior in lithium-ion batteries“. In: *Journal of Energy Storage* 32 (2020), S. 101710. DOI: 10.1016/j.est.2020.101710.
- [57] W. Diao, Y. Xing, S. Saxena und M. Pecht. „Evaluation of Present Accelerated Temperature Testing and Modeling of Batteries“. In: *Applied Sciences* 8.10 (2018), S. 1786. DOI: 10.3390/app8101786.

- [58] S. X. Ding. *Data-driven Design of Fault Diagnosis and Fault-tolerant Control Systems*. London: Springer London, 2014. DOI: 10.1007/978-1-4471-6410-4.
- [59] S. X. Ding. *Model-Based Fault Diagnosis Techniques*. London: Springer, 2013. DOI: 10.1007/978-1-4471-4799-2.
- [60] J. Du, Z. Liu und Y. Wang. „State of charge estimation for Li-ion battery based on model from extreme learning machine“. In: *Control Engineering Practice* 26 (2014), S. 11–19. DOI: 10.1016/j.conengprac.2013.12.014.
- [61] M. Dubarry, G. Baure, C. Pastor-Fernández, T. F. Yu, W. D. Widanage und J. Marco. „Battery energy storage system modeling: A combined comprehensive approach“. In: *Journal of Energy Storage* 21 (2019), S. 172–185. DOI: 10.1016/j.est.2018.11.012.
- [62] M. Dubarry und B. Y. Liaw. „Identify capacity fading mechanism in a commercial LiFePO<sub>4</sub> cell“. In: *Journal of Power Sources* 194.1 (2009), S. 541–549. DOI: 10.1016/j.jpowsour.2009.05.036.
- [63] M. Dubarry, C. Truchot und B. Y. Liaw. „Cell degradation in commercial LiFePO<sub>4</sub> cells with high-power and high-energy designs“. In: *Journal of Power Sources* 258 (2014), S. 408–419. DOI: 10.1016/j.jpowsour.2014.02.052.
- [64] M. Dubarry, N. Vuillaume und B. Y. Liaw. „From single cell model to battery pack simulation for Li-ion batteries“. In: *Journal of Power Sources* 186.2 (2009), S. 500–507. DOI: 10.1016/j.jpowsour.2008.10.051.
- [65] M. Dubarry, N. Vuillaume und B. Y. Liaw. „Origins and accommodation of cell variations in Li-ion battery pack modeling“. In: *International Journal of Energy Research* 34.2 (2010), S. 216–231. DOI: 10.1002/er.1668.
- [66] A. L. Dulmage und N. S. Mendelsohn. „Coverings of Bipartite Graphs“. In: *Canadian Journal of Mathematics* 10.10 (1958), S. 517–534. DOI: 10.4153/CJM-1958-052-0.
- [67] L.-R. Dung, H.-F. Yuan, J.-H. Yen, C.-H. She und M.-H. Lee. „A Lithium-Ion Battery Simulator Based on a Diffusion and Switching Overpotential Hybrid Model for Dynamic Discharging Behavior and Runtime Predictions“. In: *Energies* 9.1 (2016), S. 51. DOI: 10.3390/en9010051.
- [68] A. Eddahech, O. Briat und J.-M. Vinassa. „Thermal characterization of a high-power lithium-ion battery: Potentiometric and calorimetric measurement of entropy changes“. In: *Energy* 61 (2013), S. 432–439. DOI: 10.1016/j.energy.2013.09.028.
- [69] C. Edwards, S. K. Spurgeon und R. J. Patton. „Sliding mode observers for fault detection and isolation“. In: *Automatica* 36.4 (2000), S. 541–553. DOI: 10.1016/S0005-1098(99)00177-6.
- [70] I. Fagarasan und S. Iliescu. „Parity equations for fault detection and isolation“. In: *2008 IEEE International Conference on Automation, Quality and Testing, Robotics* 1 (2008), S. 99–103. DOI: 10.1109/AQTR.2008.4588715.
- [71] L. Fahrmeir, C. Heumann, R. Künstler, I. Pigeot und G. Tutz. *Statistik*. Berlin, Heidelberg: Springer, 2016. DOI: 10.1007/978-3-662-50372-0.
- [72] H. Fang, X. Zhao, Y. Wang, Z. Sahinoglu, T. Wada, S. Hara und R. A. de Callafon. *State-of-charge estimation for batteries: A multi-model approach: 4 - 6 June 2014, Portland, Oregon, USA*. Piscataway, NJ: IEEE, 2014. DOI: 10.1109/ACC.2014.6858976.
- [73] X. Feng, X. He, M. Ouyang, L. Lu, P. Wu, C. Kulp und S. Prasser. „Thermal runaway propagation model for designing a safer battery pack with 25 Ah LiNi<sub>x</sub>Co<sub>y</sub>Mn<sub>z</sub>O<sub>2</sub> large format lithium ion battery“. In: *Applied Energy* 154 (2015), S. 74–91. DOI: 10.1016/j.apenergy.2015.04.118.

- [74] X. Feng, L. Lu, M. Ouyang, J. Li und X. He. „A 3D thermal runaway propagation model for a large format lithium ion battery module“. In: *Energy* 115 (2016), S. 194–208. DOI: 10.1016/j.energy.2016.08.094.
- [75] X. Feng, Y. Pan, X. He, Li Wang und M. Ouyang. „Detecting the internal short circuit in large-format lithium-ion battery using model-based fault-diagnosis algorithm“. In: *Journal of Energy Storage* 18 (2018), S. 26–39. DOI: 10.1016/j.est.2018.04.020.
- [76] X. Feng, C. Weng, M. Ouyang und J. Sun. „Online internal short circuit detection for a large format lithium ion battery“. In: *Applied Energy* 161 (2016), S. 168–180. DOI: 10.1016/j.apenergy.2015.10.019.
- [77] X. Feng, C. Xu, X. He, L. Wang, G. Zhang und M. Ouyang. „Mechanisms for the evolution of cell variations within a LiNixCoyMnzO2/graphite lithium-ion battery pack caused by temperature non-uniformity“. In: *Journal of Cleaner Production* 205 (2018), S. 447–462. DOI: 10.1016/j.jclepro.2018.09.003.
- [78] Y. Firouz, N. Omar, P. van den Bossche und J. van Mierlo. „Electro-Thermal Modeling of New Prismatic Lithium-Ion Capacitors: 27 - 30 Oct. 2014, Coimbra“. In: *2014 IEEE Vehicle Power and Propulsion Conference (VPPC)* (2014), S. 1–6. DOI: 10.1109/VPPC.2014.7007059.
- [79] C. Forgez, D. Vinh Do, G. Friedrich, M. Morcrette und C. Delacourt. „Thermal modeling of a cylindrical LiFePO4/graphite lithium-ion battery“. In: *Journal of Power Sources* 195.9 (2010), S. 2961–2968. DOI: 10.1016/j.jpowsour.2009.10.105.
- [80] A. Fotouhi, D. J. Auger, K. Propp, S. Longo und M. Wild. „A review on electric vehicle battery modelling: From Lithium-ion toward Lithium–Sulphur“. In: *Renewable and Sustainable Energy Reviews* 56 (2016), S. 1008–1021. DOI: 10.1016/j.rser.2015.12.009.
- [81] T. Franke und J. F. Krems. „Understanding charging behaviour of electric vehicle users“. In: *Transportation Research Part F: Traffic Psychology and Behaviour* 21 (2013), S. 75–89. DOI: 10.1016/j.trf.2013.09.002.
- [82] E. Frisk und M. Krysander. „Sensor placement for maximum fault isolability“. In: *18th International Workshop on Principles of Diagnosis (DX-07)* (2007).
- [83] S. A. Gadsden und S. R. Habibi. „Model-based fault detection of a battery system in a hybrid electric vehicle“. In: *2011 IEEE Vehicle Power and Propulsion Conference* (2011), S. 1–6. DOI: 10.1109/VPPC.2011.6043175.
- [84] N. B. Gallagher, B. M. Wise, S. W. Butler, D. D. White und G. G. Barna. „Development and Benchmarking of Multivariate Statistical Process Control Tools for a Semiconductor Etch Process: Improving Robustness through Model Updating“. In: *IFAC Proceedings Volumes* 30.9 (1997), S. 79–84. DOI: 10.1016/S1474-6670(17)43143-0.
- [85] L. Gao, S. Liu und R. A. Dougal. „Dynamic lithium-ion battery model for system simulation“. In: *IEEE Transactions on Components and Packaging Technologies* 25.3 (2002), S. 495–505. DOI: 10.1109/TCAPT.2002.803653.
- [86] W. Gao, X. Li, M. Ma, Y. Fu, J. Jiang und C. Mi. „Case Study of an Electric Vehicle Battery Thermal Runaway and Online Internal Short-Circuit Detection“. In: *IEEE Transactions on Power Electronics* 36.3 (2021), S. 2452–2455. DOI: 10.1109/TPEL.2020.3013191.
- [87] W. Gao, Y. Zheng, M. Ouyang, J. Li, X. Lai und X. Hu. „Micro-Short-Circuit Diagnosis for Series-Connected Lithium-Ion Battery Packs Using Mean-Difference Model“. In: *IEEE Transactions on Industrial Electronics* 66.3 (2019), S. 2132–2142. DOI: 10.1109/TIE.2018.2838109.

- [88] D. García-Álvarez. „Fault detection using Principal Component Analysis (PCA) in a Wastewater Treatment Plant (WWTP)“. In: *Proceedings of the International Student's Scientific Conference* (2009).
- [89] E. Gebauer. „Model-Based Fault Diagnosis in Reconfigurable Battery Systems“. Masterarbeit. München: Technischen Universität München, Fakultät für Elektro- und Informationstechnik, 2020.
- [90] E. Gebauer. „Modellbasierte Fehlerdiagnose in verteilten Systemen“. Forschungspraxis. München: Technischen Universität München, Fakultät für Elektro- und Informationstechnik, 2019.
- [91] E. R. Gelso und M. Blanke. „Structural Analysis Extended with Active Fault Isolation - Methods and Algorithms“. In: *IFAC Proceedings Volumes* 42.8 (2009), S. 597–602. DOI: 10.3182/20090630-4-ES-2003.00099.
- [92] E. R. Gelso, S. M. Castillo und J. Armengol. „An Algorithm Based on Structural Analysis for Model-based Fault Diagnosis“. In: *Proceedings of the 2008 Conference on Artificial Intelligence Research and Development* 2008 (2008), S. 138–147. DOI: 10.3233/978-1-58603-925-7-138.
- [93] J. George. „Robust fault detection and isolation in stochastic systems“. In: *International Journal of Control* 85.7 (2012), S. 779–799. DOI: 10.1080/00207179.2012.666360.
- [94] J. B. Gerschler. *Ortsaufgelöste Modellbildung von Lithium-Ionen-Systemen unter spezieller Berücksichtigung der Batteriealterung: Zugl.: Rheinisch-Westfälische Technische Hochschule Aachen, Dissertation*. Bd. 63. Aachener Beiträge des ISEA. Aachen: Shaker, 2012.
- [95] M. Geun Kim. „Multivariate outliers and decompositions of mahalanobis distance“. In: *Communications in Statistics - Theory and Methods* 29.7 (2000), S. 1511–1526. DOI: 10.1080/03610920008832559.
- [96] M. Ghalkhani, F. Bahiraei, G.-A. Nazri und M. Saif. „Electrochemical–Thermal Model of Pouch-type Lithium-ion Batteries“. In: *Electrochimica Acta* 247 (2017), S. 569–587. DOI: 10.1016/j.electacta.2017.06.164.
- [97] X. Gong, R. Xiong und C. C. Mi. „Study of the Characteristics of Battery Packs in Electric Vehicles With Parallel-Connected Lithium-Ion Battery Cells“. In: *IEEE Transactions on Industry Applications* 51.2 (2015), S. 1872–1879. DOI: 10.1109/TIA.2014.2345951.
- [98] L. Greve und C. Fehrenbach. „Mechanical testing and macro-mechanical finite element simulation of the deformation, fracture, and short circuit initiation of cylindrical Lithium ion battery cells“. In: *Journal of Power Sources* 214 (2012), S. 377–385. DOI: 10.1016/j.jpowsour.2012.04.055.
- [99] *Guide for the use of monitor systems for lead-acid traction batteries*. IEC TR 61431:1995, 1995.
- [100] L. Guo, M. Ramaswamy, M. Pyne, B. J. Yurkovich und S. Yurkovich. „Modeling and experimental validation of series connected battery pack modules“. In: *2017 IEEE Conference on Control Technology and Applications* (2017), S. 859–865. DOI: 10.1109/CCTA.2017.8062567.
- [101] F. Gustafsson. „Statistical signal processing approaches to fault detection“. In: *Annual Reviews in Control* 31.1 (2007), S. 41–54. DOI: 10.1016/j.arcontrol.2007.02.004.
- [102] W. F. Guthrie. *NIST/SEMATECH e-Handbook of Statistical Methods (NIST Handbook 151)*. National Institute of Standards and Technology, 2013. DOI: 10.18434/M32189.
- [103] A. Hagenblad, F. Gustafsson und I. Klein. „A comparison of two methods for stochastic fault detection: the parity space approach and principal components analysis“. In: *IFAC Proceedings Volumes* 36.16 (2003), S. 1053–1058. DOI: 10.1016/S1474-6670(17)34898-X.
- [104] A. Haghani Abandan Sari. *Data-Driven Design of Fault Diagnosis Systems*. Wiesbaden: Springer Fachmedien Wiesbaden, 2014. DOI: 10.1007/978-3-658-05807-4.

- [105] S. N. Haider, Q. Zhao und X. Li. „Data driven battery anomaly detection based on shape based clustering for the data centers class“. In: *Journal of Energy Storage* 29 (2020), S. 101479. DOI: 10.1016/j.est.2020.101479.
- [106] E. Hairer und G. Wanner. *Solving Ordinary Differential Equations II: Stiff and Differential-Algebraic Problems*. Bd. 14. Springer series in computational mathematics. Berlin und Heidelberg: Springer, 1991. DOI: 10.1007/978-3-662-09947-6.
- [107] C. Hanzl, C. Hartmann, M. Hölzle, B. Liebhart, M. Schmid und C. Endisch. „Current Commutation in a Switched Lithium-Ion Cell used in Cascaded Half-Bridge Multilevel Inverters“. In: *IET Power Electronics* 14.6 (2021), S. 1073–1088. DOI: 10.1049/pe12.12088.
- [108] K. S. Hariharan und V. Senthil Kumar. „A nonlinear equivalent circuit model for lithium ion cells“. In: *Journal of Power Sources* 222 (2013), S. 210–217. DOI: 10.1016/j.jpowsour.2012.08.090.
- [109] R. Hausbrand, G. Cherkashinin, H. Ehrenberg, M. Gröting, K. Albe, C. Hess und W. Jaegermann. „Fundamental degradation mechanisms of layered oxide Li-ion battery cathode materials: Methodology, insights and novel approaches“. In: *Materials Science and Engineering: B* 192 (2015), S. 3–25. DOI: 10.1016/j.mseb.2014.11.014.
- [110] P. Haussmann und J. Melbert. „Internal Cell Temperature Measurement and Thermal Modeling of Lithium Ion Cells for Automotive Applications by Means of Electrochemical Impedance Spectroscopy“. In: *SAE International Journal of Alternative Powertrains* 6.2 (2017), S. 261–270. DOI: 10.4271/2017-01-1215.
- [111] S. Haykin, Hrsg. *Kalman Filtering and Neural Networks*. Wiley series on adaptive and learning systems for signal processing, communications, and control. New York, USA: John Wiley & Sons, Inc, 2001. DOI: 10.1002/0471221546.
- [112] S. S. Haykin. *Neural networks: A comprehensive foundation*. 2. ed. Upper Saddle River, NJ und London: Prentice Hall und Prentice-Hall International, 1999.
- [113] H. He, Z. Liu und Y. Hua. „Adaptive Extended Kalman Filter Based Fault Detection and Isolation for a Lithium-Ion Battery Pack“. In: *Energy Procedia* 75 (2015), S. 1950–1955. DOI: 10.1016/j.egypro.2015.07.230.
- [114] H. He, R. Xiong und J. Fan. „Evaluation of Lithium-Ion Battery Equivalent Circuit Models for State of Charge Estimation by an Experimental Approach“. In: *Energies* 4.4 (2011), S. 582–598. DOI: 10.3390/en4040582.
- [115] F. Helling, J. Glück, A. Singer, H.-J. Pfisterer und T. Weyh. „The AC battery – A novel approach for integrating batteries into AC systems“. In: *International Journal of Electrical Power & Energy Systems* 104 (2019), S. 150–158. DOI: 10.1016/j.ijepes.2018.06.047.
- [116] S. Hillebrand. „Parameteridentifikation für Batteriezellen“. Masterarbeit. München: Technischen Universität München, Fakultät für Elektro- und Informationstechnik, 2019.
- [117] J. Hong, Z. Wang und P. Liu. „Big-Data-Based Thermal Runaway Prognosis of Battery Systems for Electric Vehicles“. In: *Energies* 10.7 (2017), S. 919. DOI: 10.3390/en10070919.
- [118] J. Hong, Z. Wang und P. Liu. „Voltage Fault Precaution and Safety Management of Lithium-ion Batteries Based on Entropy for Electric Vehicles“. In: *Energy Procedia* 104 (2016), S. 44–49. DOI: 10.1016/j.egypro.2016.12.009.
- [119] R. W. Hopkins, P. Miller, R. E. Swanson und J. J. Scheible. „Method of controlling a manufacturing process using multivariate analysis“. US Patent 5,442,562. 1995.

- [120] X. Hu, S. Lin, S. Stanton und W. Lian. „A Foster Network Thermal Model for HEV/EV Battery Modeling“. In: *IEEE Transactions on Industry Applications* 47.4 (2011), S. 1692–1699. DOI: 10.1109/TIA.2011.2155012.
- [121] X. Hu, S. Li und H. Peng. „A comparative study of equivalent circuit models for Li-ion batteries“. In: *Journal of Power Sources* 198 (2012), S. 359–367. DOI: 10.1016/j.jpowsour.2011.10.013.
- [122] X. Hu, W. Liu, X. Lin und Y. Xie. „A Comparative Study of Control-Oriented Thermal Models for Cylindrical Li-Ion Batteries“. In: *IEEE Transactions on Transportation Electrification* 5.4 (2019), S. 1237–1253. DOI: 10.1109/TTE.2019.2953606.
- [123] X. Hu, K. Zhang, K. Liu, X. Lin, S. Dey und S. Onori. „Advanced Fault Diagnosis for Lithium-Ion Battery Systems: A Review of Fault Mechanisms, Fault Features, and Diagnosis Procedures“. In: *IEEE Industrial Electronics Magazine* 14.3 (2020), S. 65–91. DOI: 10.1109/MIE.2020.2964814.
- [124] Y. Hu, S. Yurkovich, Y. Guezennec und B. J. Yurkovich. „Electro-thermal battery model identification for automotive applications“. In: *Journal of Power Sources* 196.1 (2011), S. 449–457. DOI: 10.1016/j.jpowsour.2010.06.037.
- [125] L. Huang, Z. Zhang, Z. Wang, L. Zhang, X. Zhu und D. D. Dorrell. „Thermal runaway behavior during overcharge for large-format Lithium-ion batteries with different packaging patterns“. In: *Journal of Energy Storage* 25 (2019), S. 100811. DOI: 10.1016/j.est.2019.100811.
- [126] T. Huria, M. Ceraolo, J. Gazzarri und R. Jackey. „High fidelity electrical model with thermal dependence for characterization and simulation of high power lithium battery cells“. In: *2012 IEEE International Electric Vehicle Conference*. Hrsg. von I. Staff. IEEE, 2012, S. 1–8. DOI: 10.1109/IEVC.2012.6183271.
- [127] R. Isermann. *Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance*. Berlin, Heidelberg: Springer, 2006. DOI: 10.1007/3-540-30368-5.
- [128] J.-C. Jeng. „Adaptive process monitoring using efficient recursive PCA and moving window PCA algorithms“. In: *Journal of the Taiwan Institute of Chemical Engineers* 41.4 (2010), S. 475–481. DOI: 10.1016/j.jtice.2010.03.015.
- [129] F. Ji, L. Liao, T. Wu, C. Chang und M. Wang. „Self-reconfiguration batteries with stable voltage during the full cycle without the DC-DC converter“. In: *Journal of Energy Storage* 28 (2020). DOI: 10.1016/j.est.2020.101213.
- [130] F. Jin, H. Yongling und W. Guofu. „Comparison Study of Equivalent Circuit Model of Li-Ion Battery for Electrical Vehicles“. In: *Research Journal of Applied Sciences, Engineering and Technology* 6.20 (2013), S. 3756–3759. DOI: 10.19026/rjaset.6.3587.
- [131] V. H. Johnson. „Battery performance models in ADVISOR“. In: *Journal of Power Sources* 110.2 (2002), S. 321–329. DOI: 10.1016/S0378-7753(02)00194-5.
- [132] E. M. Jordaan. *Development of robust inferential sensors : industrial applications of support vector machines for regression*. 2002. DOI: 10.6100/IR561175.
- [133] A. Jossen und W. Weydanz. *Moderne Akkumulatoren richtig einsetzen*. 1. Auflage. Neusäß: Ubooks-Verlag, 2006.
- [134] D. Jung, Y. Dong, E. Frisk, M. Krysander und G. Biswas. „Sensor selection for fault diagnosis in uncertain systems“. In: *International Journal of Control* 104 (2018), S. 1–11. DOI: 10.1080/00207179.2018.1484171.

- [135] D. Jung, H. Khorasgani, E. Frisk, M. Krysander und G. Biswas. „Analysis of fault isolation assumptions when comparing model-based design approaches of diagnosis systems“. In: *IFAC-PapersOnLine* 48.21 (2015), S. 1289–1296. DOI: 10.1016/j.ifacol.2015.09.703.
- [136] R. E. Kalman. „A New Approach to Linear Filtering and Prediction Problems“. In: *Journal of Basic Engineering* 82.1 (1960), S. 35–45. DOI: 10.1115/1.3662552.
- [137] Y. Kang, B. Duan, Z. Zhou, Y. Shang und C. Zhang. „A multi-fault diagnostic method based on an interleaved voltage measurement topology for series connected battery packs“. In: *Journal of Power Sources* 417 (2019), S. 132–144. DOI: 10.1016/j.jpowsour.2019.01.058.
- [138] Y. Kang, B. Duan, Z. Zhou, Y. Shang und C. Zhang. „Online multi-fault detection and diagnosis for battery packs in electric vehicles“. In: *Applied Energy* 259 (2020), S. 114170. DOI: 10.1016/j.apenergy.2019.114170.
- [139] T. C. Kaypmaz und R. N. Tuncay. „An advanced cell model for diagnosing faults in operation of Li-ion Polymer batteries“. In: *2011 IEEE Vehicle Power and Propulsion Conference (VPPC 2011)*. Piscataway, NJ: IEEE, 2011, S. 1–5. DOI: 10.1109/VPPC.2011.6043007.
- [140] P. Keil. *Aufbau und Parametrierung von Batteriemodellen*. Hrsg. von Technische Universität München, Lehrstuhl für Elektrische Energiespeichertechnik. 2011.
- [141] P. Keil, S. F. Schuster, J. Wilhelm, J. Travi, A. Hauser, R. C. Karl und A. Jossen. „Calendar Aging of Lithium-Ion Batteries“. In: *Journal of The Electrochemical Society* 163.9 (2016), A1872–A1880. DOI: 10.1149/2.0411609jes.
- [142] B. de Ketelaere, M. Hubert und E. Schmitt. „Overview of PCA-Based Statistical Process-Monitoring Methods for Time-Dependent, High-Dimensional Data“. In: *Journal of Quality Technology* 47.4 (2015), S. 318–335. DOI: 10.1080/00224065.2015.11918137.
- [143] J. Kim und B. H. Cho. „An innovative approach for characteristic analysis and state-of-health diagnosis for a Li-ion cell based on the discrete wavelet transform“. In: *Journal of Power Sources* 260 (2014), S. 115–130. DOI: 10.1016/j.jpowsour.2014.02.100.
- [144] J. Kleiner, R. Singh, M. Schmid, L. Komsijska, G. Elger und C. Endisch. „Influence of Heat Pipe Assisted Terminal Cooling on the Thermal Behavior of a Large Prismatic Lithium-Ion Cell during Fast Charging in Electric Vehicles“. In: *Applied Thermal Engineering* (2020), S. 116328. DOI: 10.1016/j.applthermaleng.2020.116328.
- [145] H.-G. Kneidinger. „Datengetriebene Zellüberwachung zur Fehlerdiagnose in Batteriesystemen“. Masterarbeit. München: Technischen Universität München, Fakultät für Elektro- und Informationstechnik, 2019.
- [146] L. Komsijska, T. Buchberger, S. Diehl, M. Ehrensberger, C. Hanzl, C. Hartmann, M. Hölzle, J. Kleiner, M. Lewerenz, B. Liebhart, M. Schmid, D. Schneider, S. Speer, J. Stöttner, C. Terbrack, M. Hinterberger und C. Endisch. „Critical Review of Intelligent Battery Systems: Challenges, Implementation, and Potential for Electric Vehicles“. In: *Energies* 14.18 (2021), S. 5989. DOI: 10.3390/en14185989.
- [147] X. Kong, G. L. Plett, M. Scott Trimboli, Z. Zhang, D. Qiao, T. Zhao und Y. Zheng. „Pseudo-two-dimensional model and impedance diagnosis of micro internal short circuit in lithium-ion cells“. In: *Journal of Energy Storage* 27 (2020), S. 101085. DOI: 10.1016/j.est.2019.101085.
- [148] X. Kong, Y. Zheng, M. Ouyang, L. Lu, J. Li und Z. Zhang. „Fault diagnosis and quantitative analysis of micro-short circuits for lithium-ion batteries in battery packs“. In: *Journal of Power Sources* 395 (2018), S. 358–368. DOI: 10.1016/j.jpowsour.2018.05.097.



- [149] R. Korthauer. *Handbuch Lithium-Ionen-Batterien*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. DOI: 10.1007/978-3-642-30653-2.
- [150] T. Kourti und J. F. MacGregor. „Multivariate SPC Methods for Process and Product Monitoring“. In: *Journal of Quality Technology* 28.4 (1996), S. 409–428. DOI: 10.1080/00224065.1996.11979699.
- [151] U. Kruger und L. Xie. *Statistical Monitoring of Complex Multivariate Processes: With applications in industrial process control*. Statistics in practice. Chichester, UK: John Wiley & Sons, Ltd, 2012. DOI: 10.1002/9780470517253.
- [152] M. Krysander, J. Aslund und M. Nyberg. „An Efficient Algorithm for Finding Minimal Overconstrained Subsystems for Model-Based Diagnosis“. In: *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans* 38.1 (2008), S. 197–206. DOI: 10.1109/TSMCA.2007.909555.
- [153] M. Krysander und E. Frisk. „Sensor Placement for Fault Diagnosis“. In: *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans* 38.6 (2008), S. 1398–1410. DOI: 10.1109/TSMCA.2008.2003968.
- [154] M. Krysander. „Design and Analysis of Diagnosis Systems Using Structural Methods“. Dissertation. Linköping: Linköpings universitet, 2006.
- [155] P. Kurzweil und O. K. Dietlmeier. *Elektrochemische Speicher*. Wiesbaden: Springer Fachmedien Wiesbaden, 2015. DOI: 10.1007/978-3-658-10900-4.
- [156] X. Lai, W. Yi, X. Kong, X. Han, L. Zhou, T. Sun und Y. Zheng. „Online detection of early stage internal short circuits in series-connected lithium-ion battery packs based on state-of-charge correlation“. In: *Journal of Energy Storage* 30 (2020), S. 101514. DOI: 10.1016/j.est.2020.101514.
- [157] J.-M. Lee, C. Yoo, S. W. Choi, P. A. Vanrolleghem und I.-B. Lee. „Nonlinear process monitoring using kernel principal component analysis“. In: *Chemical Engineering Science* 59.1 (2004), S. 223–234. DOI: 10.1016/j.ces.2003.09.012.
- [158] R. A. Leising, M. J. Palazzo, E. S. Takeuchi und K. J. Takeuchi. „A study of the overcharge reaction of lithium-ion batteries“. In: *Journal of Power Sources* 97-98 (2001), S. 681–683. DOI: 10.1016/S0378-7753(01)00598-5.
- [159] Lennart Ljung. *System Identification: Theory for the user*. 2. Aufl. Upper Saddle River, NJ, USA: Prentice Hall PTR, 1999.
- [160] M. Lewerenz, A. Marongiu, A. Warnecke und D. U. Sauer. „Differential voltage analysis as a tool for analyzing inhomogeneous aging: A case study for LiFePO<sub>4</sub>|Graphite cylindrical cells“. In: *Journal of Power Sources* 368 (2017), S. 57–67. DOI: 10.1016/j.jpowsour.2017.09.059.
- [161] W. Li, H. Yue, S. Valle-Cervantes und S. Qin. „Recursive PCA for adaptive process monitoring“. In: *Journal of Process Control* 10.5 (2000), S. 471–486. DOI: 10.1016/S0959-1524(00)00022-6.
- [162] X. Li und Z. Wang. „A novel fault diagnosis method for lithium-Ion battery packs of electric vehicles“. In: *Measurement* 116 (2018), S. 402–411. DOI: 10.1016/j.measurement.2017.11.034.
- [163] B. Liebhart, S. Diehl, M. Schmid, C. Endisch und R. Kennel. „Improved Impedance Measurements for Electric Vehicles with Reconfigurable Battery Systems“. In: *2021 IEEE 12th Energy Conversion Congress & Exposition - Asia (ECCE-Asia)*. IEEE, 2021, S. 1736–1742. DOI: 10.1109/ECCE-Asia49820.2021.9479060.
- [164] B. Liebhart, L. Komsijska und C. Endisch. „Passive impedance spectroscopy for monitoring lithium-ion battery cells during vehicle operation“. In: *Journal of Power Sources* 449 (2020). DOI: 10.1016/j.jpowsour.2019.227297.

- [165] B. Liebhart, C. Terbrack, M. Schmid, D. Schneider, M. Hinterberger und C. Endisch. „Verfahren zum Betreiben eines Batteriesystems für ein Kraftfahrzeug, um eine Diagnosemessung durchzuführen, sowie Batteriesystem für ein Kraftfahrzeug und Kraftfahrzeug“. DE102019211082A1. Deutsches Patent- und Markenamt. 25.07.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192110827>.
- [166] T. Lin, Z. Chen, C. Zheng, D. Huang und S. Zhou. „Fault diagnosis of lithium-ion battery pack based on hybrid system and dual extended Kalman filter algorithm“. In: *IEEE Transactions on Transportation Electrification* (2020), S. 1. DOI: 10.1109/TTE.2020.3006064.
- [167] X. Lin, H. E. Perez, S. Mohan, J. B. Siegel, A. G. Stefanopoulou, Y. Ding und M. P. Castanier. „A lumped-parameter electro-thermal model for cylindrical batteries“. In: *Journal of Power Sources* 257 (2014), S. 1–11. DOI: 10.1016/j.jpowsour.2014.01.097.
- [168] X. Lin, H. E. Perez, J. B. Siegel, A. G. Stefanopoulou, Y. Li, R. D. Anderson, Y. Ding und M. P. Castanier. „Online Parameterization of Lumped Thermal Dynamics in Cylindrical Lithium Ion Batteries for Core Temperature Estimation and Health Monitoring“. In: *IEEE Transactions on Control Systems Technology* 21.5 (2013), S. 1745–1755. DOI: 10.1109/TCST.2012.2217143.
- [169] B. Liu, Y. Jia, C. Yuan, L. Wang, X. Gao, S. Yin und J. Xu. „Safety issues and mechanisms of lithium-ion battery cell upon mechanical abusive loading: A review“. In: *Energy Storage Materials* 24 (2020), S. 85–112. DOI: 10.1016/j.ensm.2019.06.036.
- [170] P. Liu, Z. Sun, Z. Wang und J. Zhang. „Entropy-Based Voltage Fault Diagnosis of Battery Systems for Electric Vehicles“. In: *Energies* 11.1 (2018), S. 136. DOI: 10.3390/en11010136.
- [171] Z. Liu, Q. Ahmed, G. Rizzoni und H. He. „Fault Detection and Isolation for Lithium-Ion Battery System Using Structural Analysis and Sequential Residual Generation“. In: *ASME 2014 Dynamic Systems and Control Conference, DSCC 2014* 2 (2014). DOI: 10.1115/DSCC2014-6101.
- [172] Z. Liu, Q. Ahmed, J. Zhang, G. Rizzoni und H. He. „Structural analysis based sensors fault detection and isolation of cylindrical lithium-ion batteries in automotive applications“. In: *Control Engineering Practice* 52 (2016), S. 46–58. DOI: 10.1016/j.conengprac.2016.03.015.
- [173] Z. Liu und H. He. „Model-based Sensor Fault Diagnosis of a Lithium-ion Battery in Electric Vehicles“. In: *Energies* 8.7 (2015), S. 6509–6527. DOI: 10.3390/en8076509.
- [174] Z. Liu und H. He. „Sensor fault detection and isolation for a lithium-ion battery pack in electric vehicles using adaptive extended Kalman filter“. In: *Applied Energy* 185 (2017), S. 2033–2044. DOI: 10.1016/j.apenergy.2015.10.168.
- [175] Z. Liu, H. He, Q. Ahmed und G. Rizzoni. „Structural Analysis Based Fault Detection and Isolation Applied for A Lithium-Ion Battery Pack“. In: *IFAC-PapersOnLine* 48.21 (2015), S. 1465–1470. DOI: 10.1016/j.ifacol.2015.09.731.
- [176] W. Lombardi, M. Zarudniev, S. Lesecq und S. Bacquet. „Sensors fault diagnosis for a BMS“. In: *2014 European Control Conference (ECC 2014)*. Piscataway, NJ: IEEE, 2014, S. 952–957. DOI: 10.1109/ECC.2014.6862432.
- [177] V. Lorentz, M. Wenger, M. Giegerich, S. Zeltner, M. März, L. Frey und G. Meyer. *Smart Battery Cell Monitoring with Contactless Data Transmission*. Berlin, Heidelberg: Springer, 2012. DOI: 10.1007/978-3-642-29673-4\_2.
- [178] L. Lu, X. Han, J. Li, J. Hua und M. Ouyang. „A review on the key issues for lithium-ion battery management in electric vehicles“. In: *Journal of Power Sources* 226 (2013), S. 272–288. DOI: 10.1016/j.jpowsour.2012.10.060.

- [179] S. Ludwig, I. Zilberman, M. F. Horsche, T. Wohlers und A. Jossen. „Pulse resistance based online temperature estimation for lithium-ion cells“. In: *Journal of Power Sources* 490 (2021), S. 229523. DOI: 10.1016/j.jpowsour.2021.229523.
- [180] C. Lyness, M. Fleischhammer, M. Abert, B. Barnett, C. H. McCoy, Ofer David, S. Sriramulu, M. Gilljam, H. Weydahl, S. Forseth, P. J. Vie und T. Lian. „Lithium-Secondary Cell“. In: *Li-battery safety*. Hrsg. von J. Garche und K. Brandt. Electrochemical power sources. San Diego: Elsevier, 2019, S. 143–266. DOI: 10.1016/B978-0-444-63777-2.00007-4.
- [181] D. Lyu, B. Ren und S. Li. „Failure modes and mechanisms for rechargeable Lithium-based batteries: a state-of-the-art review“. In: *Acta Mechanica* 230.3 (2019), S. 701–727. DOI: 10.1007/s00707-018-2327-8.
- [182] H. Ma, L. Yan, Y. Xia und M. Fu. *Kalman Filtering and Information Fusion*. Singapore: Springer Singapore, 2020. DOI: 10.1007/978-981-15-0806-6.
- [183] M. Ma, Y. Wang, Q. Duan, T. Wu, J. Sun und Q. Wang. „Fault detection of the connection of lithium-ion power batteries in series for electric vehicles based on statistical analysis“. In: *Energy* 164 (2018), S. 745–756. DOI: 10.1016/j.energy.2018.09.047.
- [184] J. F. MacGregor und T. Kourti. „Statistical process control of multivariate processes“. In: *Control Engineering Practice* 3.3 (1995), S. 403–414. DOI: 10.1016/0967-0661(95)00014-L.
- [185] J. F. MacGregor, C. Jaeckle, C. Kiparissides und M. Koutoudi. „Process monitoring and diagnosis by multiblock PLS methods“. In: *AIChE Journal* 40.5 (1994), S. 826–838. DOI: 10.1002/aic.690400509.
- [186] K. Makinejad, R. Arunachala, S. Arnold, H. Ennifar, H. Zhou, A. Jossen und W. Changyun. „A Lumped Electro-Thermal Model for Li-Ion Cells in Electric Vehicle Application“. In: *World Electric Vehicle Journal* 7.1 (2015), S. 1–13. DOI: 10.3390/wevj7010001.
- [187] H. Maleki und J. N. Howard. „Effects of overdischarge on performance and thermal stability of a Li-ion cell“. In: *Journal of Power Sources* 160.2 (2006), S. 1395–1402. DOI: 10.1016/j.jpowsour.2006.03.043.
- [188] H. Maleki und J. N. Howard. „Internal short circuit in Li-ion cells“. In: *Journal of Power Sources* 191.2 (2009), S. 568–574. DOI: 10.1016/j.jpowsour.2009.02.070.
- [189] J. F. Manwell und J. G. McGowan. „Lead acid battery storage model for hybrid energy systems“. In: *Solar Energy* 50.5 (1993), S. 399–405. DOI: 10.1016/0038-092X(93)90060-2.
- [190] R. Marchthaler und S. Dingler. *Kalman-Filter*. Wiesbaden: Springer Fachmedien Wiesbaden, 2017. DOI: 10.1007/978-3-658-16728-8.
- [191] J. Marcicki, S. Onori und G. Rizzoni. „Nonlinear Fault Detection and Isolation for a Lithium-Ion Battery Management System“. In: *Proceedings of the ASME 2010 Dynamic Systems and Control Conference*. New York, NY: ASME, 2010, S. 607–614. DOI: 10.1115/DSCC2010-4085.
- [192] R. B. Marimont und M. B. Shapiro. „Nearest Neighbour Searches and the Curse of Dimensionality“. In: *IMA Journal of Applied Mathematics* 24.1 (1979), S. 59–70. DOI: 10.1093/imamat/24.1.59.
- [193] T. Mauk. *Selbstlernende, zuverlässigkeitsorientierte Prädiktion energetisch relevanter Größen im Kraftfahrzeug: Zugl.: Universität Stuttgart, Dissertation*. Bd. 55. Schriftenreihe des Instituts für Verbrennungsmotoren und Kraftfahrwesen der Universität Stuttgart. Renningen: Expert-Verl., 2011.
- [194] N. Mehranbod, M. Soroush, M. Piovoso und B. A. Ogunnaike. „Probabilistic model for sensor fault detection and identification“. In: *AIChE Journal* 49.7 (2003), S. 1787–1802. DOI: 10.1002/aic.690490716.

- [195] J. Meng, M. Boukhifer, C. Delpha und D. Diallo. „Incipient short-circuit fault diagnosis of lithium-ion batteries“. In: *Journal of Energy Storage* 31 (2020), S. 101658. DOI: 10.1016/j.est.2020.101658.
- [196] J. Meng, G. Luo und F. Gao. „Lithium Polymer Battery State-of-Charge Estimation Based on Adaptive Unscented Kalman Filter and Support Vector Machine“. In: *IEEE Transactions on Power Electronics* 31.3 (2016), S. 2226–2238. DOI: 10.1109/TPEL.2015.2439578.
- [197] J. Meng, G. Luo, M. Ricco, M. Swierczynski, D.-I. Stroe und R. Teodorescu. „Overview of Lithium-Ion Battery Modeling Methods for State-of-Charge Estimation in Electrical Vehicles“. In: *Applied Sciences* 8.5 (2018), S. 659. DOI: 10.3390/app8050659.
- [198] A. Mesbah, S. Streif, R. Findeisen und R. D. Braatz. „Active Fault Diagnosis for Nonlinear Systems with Probabilistic Uncertainties: 19th IFAC World Congress“. In: *IFAC Proceedings Volumes* 47.3 (2014), S. 7079–7084. DOI: 10.3182/20140824-6-ZA-1003.01594.
- [199] P. Miller, R. E. Swanson und C. E. Heckler. „Contribution plots: a missing link in multivariate quality control“. In: *Applied mathematics and computer science* 8.4 (1998), S. 775–792.
- [200] S. Miyamoto, K. Honda und H. Ichihashi. *Algorithms for Fuzzy Clustering: Methods in c-Means Clustering with Applications*. Bd. 229. Studies in Fuzziness and Soft Computing. Berlin und Heidelberg: Springer, 2008. DOI: 10.1007/978-3-540-78737-2.
- [201] B. Moore. „Principal component analysis in linear systems: Controllability, observability, and model reduction“. In: *IEEE Transactions on Automatic Control* 26.1 (1981), S. 17–32. DOI: 10.1109/TAC.1981.1102568.
- [202] V. K. S. Muddappa und S. Anwar. „Electrochemical Model Based Fault Diagnosis of Li-Ion Battery Using Fuzzy Logic“. In: *Proceedings of the ASME International Mechanical Engineering Congress and Exposition - 2014*. New York, NY: ASME, 2015. DOI: 10.1115/IMECE2014-37134.
- [203] M. Naghshvar und T. Javidi. „Active sequential hypothesis testing“. In: *The Annals of Statistics* 41.6 (2013), S. 2703–2738. DOI: 10.1214/13-AOS1144.
- [204] M. Naghshvar und T. Javidi. „Information utility in active sequential hypothesis testing“. In: *48th Annual Allerton Conference on Communication, Control, and Computing (Allerton)*. Piscataway, NJ, 2010, S. 123–129. DOI: 10.1109/ALLERTON.2010.5706897.
- [205] M. Naghshvar und T. Javidi. „Sequentiality and Adaptivity Gains in Active Hypothesis Testing“. In: *IEEE Journal of Selected Topics in Signal Processing* 7.5 (2013), S. 768–782. DOI: 10.1109/JSTSP.2013.2261279.
- [206] S. Nitinawarat, G. K. Atia und V. V. Veeravalli. „Controlled sensing for hypothesis testing“. In: *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Piscataway, NJ, 2012, S. 5277–5280. DOI: 10.1109/ICASSP.2012.6289111.
- [207] G. J. Offer, V. Yufit, D. A. Howey, B. Wu und N. P. Brandon. „Module design and fault diagnosis in electric vehicle batteries“. In: *Journal of Power Sources* 206 (2012), S. 383–392. DOI: 10.1016/j.jpowsour.2012.01.087.
- [208] O. Ojo, H. Lang, Y. Kim, X. Hu, B. Mu und X. Lin. „A Neural Network-Based Method for Thermal Fault Detection in Lithium-Ion Batteries“. In: *IEEE Transactions on Industrial Electronics* (2020), S. 1. DOI: 10.1109/TIE.2020.2984980.
- [209] S. Orcioni, L. Buccolini, A. Ricci und M. Conti. „Lithium-ion Battery Electrothermal Model, Parameter Estimation, and Simulation Environment“. In: *Energies* 10.3 (2017), S. 375. DOI: 10.3390/en10030375.

- [210] A. Otto, S. Rzepka, T. Mager, B. Michel, C. Lanciotti, T. Günther und O. Kanoun. *Battery Management Network for Fully Electrical Vehicles Featuring Smart Systems at Cell and Pack Level*. Berlin, Heidelberg: Springer, 2012. DOI: 10.1007/978-3-642-29673-4\_1.
- [211] M. Ouyang, M. Zhang, X. Feng, L. Lu, J. Li, X. He und Y. Zheng. „Internal short circuit detection for battery pack using equivalent parameter and consistency method“. In: *Journal of Power Sources* 294 (2015), S. 272–283. DOI: 10.1016/j.jpowsour.2015.06.087.
- [212] S. Panchal, I. Dincer, M. Agelin-Chaab, R. Fraser und M. Fowler. „Experimental and theoretical investigation of temperature distributions in a prismatic lithium-ion battery“. In: *International Journal of Thermal Sciences* 99 (2016), S. 204–212. DOI: 10.1016/j.ijthermalsci.2015.08.016.
- [213] C. Pastor-Fernández, T. Bruen, W. D. Widanage, M. A. Gama-Valdez und J. Marco. „A Study of Cell-to-Cell Interactions and Degradation in Parallel Strings: Implications for the Battery Management System“. In: *Journal of Power Sources* 329 (2016), S. 574–585. DOI: 10.1016/j.jpowsour.2016.07.121.
- [214] R. J. Patton und J. Chen. „A Review of Parity Space Approaches to Fault Diagnosis“. In: *IFAC Proceedings Volumes* 24.6 (1991), S. 65–81. DOI: 10.1016/S1474-6670(17)51124-6.
- [215] H. Peddaneni, D. Erdogmus, Y. N. Rao, A. Hegde und J. C. Principe. „Recursive principal components analysis using eigenvector matrix perturbation“. In: *Machine learning for signal processing XIV*. Hrsg. von A. Barros. Piscataway, NJ: IEEE Operations Center, 2004, S. 83–92. DOI: 10.1109/MLSP.2004.1422962.
- [216] R. Pflüger. „Ein funktionaler Kernschätzer mit verallgemeinerter Bandbreite“. Diss. 2001. DOI: 10.17877/DE290R-13067.
- [217] K. E. S. Pilario, Y. Cao und M. Shafiee. „Mixed kernel canonical variate dissimilarity analysis for incipient fault monitoring in nonlinear dynamic processes“. In: *Computers & Chemical Engineering* 123 (2019), S. 143–154. DOI: 10.1016/j.compchemeng.2018.12.027.
- [218] G. L. Plett. „Sigma-point Kalman filtering for battery management systems of LiPB-based HEV battery packs“. In: *Journal of Power Sources* 161.2 (2006), S. 1369–1384. DOI: 10.1016/j.jpowsour.2006.06.004.
- [219] I. Portnoy, K. Melendez, H. Pinzon und M. Sanjuan. „An improved weighted recursive PCA algorithm for adaptive fault detection“. In: *Control Engineering Practice* 50 (2016), S. 69–83. DOI: 10.1016/j.conengprac.2016.02.010.
- [220] N. Poulsen und H. Niemann. „Active Fault Diagnosis Based on Stochastic Tests“. In: *International Journal of Applied Mathematics and Computer Science* 18.4 (2008), S. 487–496. DOI: 10.2478/v10006-008-0043-6.
- [221] A. Pruteanu, B. V. Florean, G. M. Moraru und R. C. Ciobanu. „Development of a thermal simulation and testing model for a superior lithium-ion-polymer battery“. In: *13th International Conference on Optimization of Electrical and Electronic Equipment (OPTIM), 2012*. Hrsg. von L. R. Clotea. Piscataway, NJ: IEEE, 2012, S. 947–952. DOI: 10.1109/OPTIM.2012.6231870.
- [222] B. Pulido und C. A. Gonzalez. „Possible Conflicts: A Compilation Technique for Consistency-Based Diagnosis“. In: *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)* 34.5 (2004), S. 2192–2206. DOI: 10.1109/TSMCB.2004.835007.
- [223] J. Qi und D. Dah-Chuan Lu. „Review of battery cell balancing techniques“. In: *Australasian Universities Power Engineering Conference (AUPEC), 2014*. Hrsg. von A. Abu-Siada. Piscataway, NJ: IEEE, 2014, S. 1–6. DOI: 10.1109/AUPEC.2014.6966514.

- [224] S. J. Qin. „Data-driven Fault Detection and Diagnosis for Complex Industrial Processes“. In: *IFAC Proceedings Volumes* 42.8 (2009), S. 1115–1125. DOI: 10.3182/20090630-4-ES-2003.00184.
- [225] S. J. Qin. „Statistical process monitoring: basics and beyond“. In: *Journal of Chemometrics* 17.8-9 (2003), S. 480–502. DOI: 10.1002/cem.800.
- [226] M. Quraan, P. Tricoli, S. D Arco und L. Piegari. „Efficiency Assessment of Modular Multilevel Converters for Battery Electric Vehicles“. In: *IEEE Transactions on Power Electronics* 32.3 (2017), S. 2041–2051. DOI: 10.1109/TPEL.2016.2557579.
- [227] M. Raba. „Skriptbasierte Modellierung einer elektrischen Antriebskomponente“. Masterarbeit. Ingolstadt: Technische Hochschule Ingolstadt, Institut für Innovative Mobilität, 2019.
- [228] R. Rolt, R. Douglas, P. Nockemann und R. Best. „Full Battery Pack Modelling: An Electrical Sub-Model Using an EECM for HEV Applications“. In: *SAE Technical Paper Series*. SAE Technical Paper Series. SAE International 400 Commonwealth Drive, Warrendale, PA, United States, 2019. DOI: 10.4271/2019-01-1203.
- [229] E. Sahraei, J. Campbell und T. Wierzbicki. „Modeling and short circuit detection of 18650 Li-ion cells under mechanical abuse conditions“. In: *Journal of Power Sources* 220 (2012), S. 360–372. DOI: 10.1016/j.jpowsour.2012.07.057.
- [230] E. Sahraei, J. Meier und T. Wierzbicki. „Characterizing and modeling mechanical properties and onset of short circuit for three types of lithium-ion pouch cells“. In: *Journal of Power Sources* 247 (2014), S. 503–516. DOI: 10.1016/j.jpowsour.2013.08.056.
- [231] N. A. Samad, J. B. Siegel und A. G. Stefanopoulou. „Parameterization and Validation of a Distributed Coupled Electro-Thermal Model for Prismatic Cells“. In: *Proceedings of the ASME 2014 Dynamic Systems and Control Conference* (2014). DOI: 10.1115/DSCC2014-6321.
- [232] M. Sampath, S. Lafortune und D. Teneketzis. „Active diagnosis of discrete-event systems“. In: *IEEE Transactions on Automatic Control* 43.7 (1998), S. 908–929. DOI: 10.1109/9.701089.
- [233] L. H. Saw, Y. Ye und A. Tay. „Electro-thermal characterization of Lithium Iron Phosphate cell with equivalent circuit modeling“. In: *Energy Conversion and Management* 87 (2014), S. 367–377. DOI: 10.1016/j.enconman.2014.07.011.
- [234] M. Schmid und C. Endisch. „Control-Oriented Modeling and Simulation of Large-Scale Electric Vehicle Battery Packs [Poster]“. In: *12. Internationale Fachtagung „Kraftwerk Batterie – Advanced Battery Power“*. 2020.
- [235] M. Schmid und C. Endisch. „Online diagnosis of soft internal short circuits in series-connected battery packs using modified kernel principal component analysis“. In: *Journal of Energy Storage* 53 (2022), S. 104815. DOI: 10.1016/j.est.2022.104815.
- [236] M. Schmid und C. Endisch. „Parameterization of real-time capable models for the electrical-thermal simulation of battery behavior [Poster]“. In: *Advanced Automotive Battery Conference (AABC) Europe*. 2020.
- [237] M. Schmid, E. Gebauer und C. Endisch. „Structural Analysis in Reconfigurable Battery Systems for Active Fault Diagnosis“. In: *IEEE Transactions on Power Electronics* 36.8 (2021), S. 8672–8684. DOI: 10.1109/TPEL.2021.3049573.
- [238] M. Schmid, E. Gebauer, C. Hanzl und C. Endisch. „Active Model-Based Fault Diagnosis in Reconfigurable Battery Systems“. In: *IEEE Transactions on Power Electronics* 36.3 (2021), S. 2584–2597. DOI: 10.1109/TPEL.2020.3012964.

- [239] M. Schmid, J. Kleiner und C. Endisch. „Early detection of Internal Short Circuits in series-connected battery packs based on nonlinear process monitoring“. In: *Journal of Energy Storage* 48 (2022), S. 103732. DOI: 10.1016/j.est.2021.103732.
- [240] M. Schmid, H.-G. Kneidinger und C. Endisch. „Data-Driven Fault Diagnosis in Battery Systems Through Cross-Cell Monitoring“. In: *IEEE Sensors Journal* 21.2 (2021), S. 1829–1837. DOI: 10.1109/JSEN.2020.3017812.
- [241] M. Schmid, B. Liebhart, J. Kleiner, C. Endisch und R. Kennel. „Online Detection of Soft Internal Short Circuits in Lithium-Ion Battery Packs by Data-Driven Cell Voltage Monitoring“. In: *2021 IEEE 12th Energy Conversion Congress & Exposition - Asia (ECCE-Asia)*. IEEE, 2021, S. 1711–1718. DOI: 10.1109/ECCE-Asia49820.2021.9479175.
- [242] M. Schmid, B. Liebhart, D. Schneider, M. Hinterberger und C. Endisch. „Verfahren zur Bestimmung zumindest eines Batterieparameters einer Batterie, entsprechend betreibbare Batterie sowie Kraftfahrzeug“. DE102019201604A1. Deutsches Patent- und Markenamt. 7.02.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192016049>.
- [243] M. Schmid, D. Schneider, M. Hinterberger und C. Endisch. „Verfahren zum Durchführen eines Batterietests in einer Batterie eines Kraftfahrzeugs sowie Batterie und Kraftfahrzeug“. DE102019202463A1. Deutsches Patent- und Markenamt. 22.02.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192024637>.
- [244] M. Schmid, C. Terbrack, M. Hinterberger und C. Endisch. „Verfahren und Steuervorrichtung zum Betreiben zumindest einer Batteriezelle eines Batteriesystems eines Kraftfahrzeug“. DE102019210213A1. Deutsches Patent- und Markenamt. 10.07.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192102131>.
- [245] M. Schmid, U. Vögele und C. Endisch. „A novel matrix-vector-based framework for modeling and simulation of electric vehicle battery packs“. In: *Journal of Energy Storage* 32 (2020), S. 101736. DOI: 10.1016/j.est.2020.101736.
- [246] M. Schmid, U. Vögele, M. Hinterberger und C. Endisch. „Verfahren zum Betreiben einer Energiespeicheranordnung sowie entsprechende Energiespeicheranordnung“. DE102020112437A1. Deutsches Patent- und Markenamt. 7.05.2020. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020201124376>.
- [247] M. Schmid, U. Vögele, D. Schneider, M. Hinterberger und C. Endisch. „Verfahren zum Detektieren eines Fehlers in einem Batteriesystem sowie Batteriesystem und Kraftfahrzeug“. DE102019212909A1. Deutsches Patent- und Markenamt. 28.08.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192129099>.
- [248] M. Schmid, U. Vögele, D. Schneider, M. Hinterberger und C. Endisch. „Verfahren zum Erkennen eines Sensorausfalls in einem Batteriesystem eines Kraftfahrzeugs sowie Batteriesystem und Kraftfahrzeug“. DE102019211998A1. Deutsches Patent- und Markenamt. 9.08.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192119980>.
- [249] D. Schneider, M. Schmid, U. Vögele, M. Hinterberger und C. Endisch. „Verfahren zum Bestimmen eines Werts einer physikalischen Größe einer Zellanordnung, Bestimmungseinrichtung, Hochvoltbatterie und Kraftfahrzeug“. DE102019207354A1. Deutsches Patent- und Markenamt. 20.05.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192073549>.

- [250] D. Schneider, U. Vögele und C. Endisch. „Model-based sensor data fusion of quasi-redundant voltage and current measurements in a lithium-ion battery module“. In: *Journal of Power Sources* 440 (2019). DOI: 10.1016/j.jpowsour.2019.227156.
- [251] B. Schölkopf, A. Smola und K.-R. Müller. „Kernel principal component analysis“. In: *International conference on artificial neural networks* 1327 (1997), S. 583–588. DOI: 10.1007/BFb0020217.
- [252] S. F. Schuster, M. J. Brand, P. Berg, M. Gleissenberger und A. Jossen. „Lithium-ion cell-to-cell variation during battery electric vehicle operation“. In: *Journal of Power Sources* 297 (2015), S. 242–251. DOI: 10.1016/j.jpowsour.2015.08.001.
- [253] T. Segaran. *Programming collective intelligence: Building smart Web 2.0 applications*. 1. ed. Beijing: O’Reilly, 2007.
- [254] C. Sen und N. C. Kar. „Battery pack modeling for the analysis of battery management system of a hybrid electric vehicle“. In: *IEEE Vehicle Power and Propulsion Conference, 2009*. Piscataway, NJ: IEEE, 2009, S. 207–212. DOI: 10.1109/VPPC.2009.5289848.
- [255] M. Seo, T. Goh, M. Park und S. Kim. „Detection Method for Soft Internal Short Circuit in Lithium-Ion Battery Pack by Extracting Open Circuit Voltage of Faulted Cell“. In: *Energies* 11.7 (2018), S. 1669. DOI: 10.3390/en11071669.
- [256] M. Seo, T. Goh, M. Park, G. Koo und S. Kim. „Detection of Internal Short Circuit in Lithium Ion Battery Using Model-Based Switching Model Method“. In: *Energies* 10.1 (2017), S. 76. DOI: 10.3390/en10010076.
- [257] M. Seo, M. Park, Y. Song und S. W. Kim. „Online Detection of Soft Internal Short Circuit in Lithium-Ion Batteries at Various Standard Charging Ranges“. In: *IEEE Access* 8 (2020), S. 70947–70959. DOI: 10.1109/ACCESS.2020.2987363.
- [258] Y. Shang, G. Lu, Y. Kang, Z. Zhou, B. Duan und C. Zhang. „A multi-fault diagnosis method based on modified Sample Entropy for lithium-ion battery strings“. In: *Journal of Power Sources* 446 (2020), S. 227275. DOI: 10.1016/j.jpowsour.2019.227275.
- [259] C. She, Z. Wang, F. Sun, P. Liu und L. Zhang. „Battery Aging Assessment for Real-World Electric Buses Based on Incremental Capacity Analysis and Radial Basis Function Neural Network“. In: *IEEE Transactions on Industrial Informatics* 16.5 (2020), S. 3345–3354. DOI: 10.1109/TII.2019.2951843.
- [260] M. Shen und Q. Gao. „A review on battery management system from the modeling efforts to its multiapplication and integration“. In: *International Journal of Energy Research* 43.10 (2019), S. 5042–5075. DOI: 10.1002/er.4433.
- [261] T. Shen, A. Kilic und H.-C. Reuss. „A New System Diagnostic Method for Powertrain of Automated Electric Vehicles“. In: *IEEE International Conference on Intelligent Transportation Systems (ITSC)* (2018), S. 313–320. DOI: 10.1109/ITSC.2018.8569739.
- [262] A. Sidhu, A. Izadian und S. Anwar. „Adaptive Nonlinear Model-Based Fault Diagnosis of Li-Ion Batteries“. In: *IEEE Transactions on Industrial Electronics* 62.2 (2015), S. 1002–1011. DOI: 10.1109/TIE.2014.2336599.
- [263] D. Simon. „Kalman filtering with state constraints: a survey of linear and nonlinear algorithms“. In: *IET Control Theory & Applications* 4.8 (2010), S. 1303–1318. DOI: 10.1049/iet-cta.2009.0032.
- [264] A. Singh, A. Izadian und S. Anwar. „Fault diagnosis of Li-Ion batteries using multiple-model adaptive estimation“. In: *39th annual conference of the IEEE Industrial Electronics Society* (2013), S. 3524–3529. DOI: 10.1109/IECON.2013.6699695.



- [265] S. Skoog. „Electro-thermal modeling of high-performance lithium-ion energy storage systems including reversible entropy heat“. In: *APEC 2017*. Piscataway, NJ: IEEE, 2017, S. 2369–2373. DOI: 10.1109/APEC.2017.7931031.
- [266] D. Slišković, R. Grbić und Ž. Hocenski. „Multivariate statistical process monitoring“. In: *Tehnički Vjesnik* 19, 1 (2012), S. 33–41.
- [267] K. A. Smith, C. D. Rahn und C.-Y. Wang. „Control oriented 1D electrochemical model of lithium ion battery“. In: *Energy Conversion and Management* 48.9 (2007), S. 2565–2578. DOI: 10.1016/j.enconman.2007.03.015.
- [268] A. J. Smola und B. Schölkopf. „Sparse Greedy Matrix Approximation for Machine Learning“. In: *Proceedings of the 17. International Conference on Machine Learning* (2000), S. 911–918.
- [269] K. Somasundaram, E. Birgersson und A. S. Mujumdar. „Thermal–electrochemical model for passive thermal management of a spiral-wound lithium-ion battery“. In: *Journal of Power Sources* 203 (2012), S. 84–96. DOI: 10.1016/j.jpowsour.2011.11.075.
- [270] D.-I. Stroe, M. Swierczynski, A.-I. Stroe und S. Knudsen Kær. „Generalized Characterization Methodology for Performance Modelling of Lithium-Ion Batteries“. In: *Batteries* 2.4 (2016), S. 37. DOI: 10.3390/batteries2040037.
- [271] R. Sun, F. Tsung und L. Qu. „Evolving kernel principal component analysis for fault diagnosis“. In: *Computers & Industrial Engineering* 53.2 (2007), S. 361–371. DOI: 10.1016/j.cie.2007.06.029.
- [272] Z. Sun, P. Liu und Z. Wang. „Real-time Fault Diagnosis Method of Battery System Based on Shannon Entropy“. In: *Energy Procedia* 105 (2017), S. 2354–2359. DOI: 10.1016/j.egypro.2017.03.676.
- [273] S. Thanagasundram, R. Arunachala, K. Makinejad, T. Teutsch und A. Jossen. *A Cell Level Model for Battery Simulation: Presented at the European Electric Vehicle Congress (EEVC) Belgium*. 2012.
- [274] M. Theiler, M. Lewerenz und M. Schmid. „Investigation of the Float Current Analysis and the Float Current Settling Process via DVA on 18650 Li(NiCoAl)O<sub>2</sub>/Graphite Cells“. In: *Applied Research Conference 2021*. Hrsg. von M. Söllner und G. Pirkl. 2021, S. 463–468.
- [275] K. E. Thomas und J. Newman. „Thermal Modeling of Porous Insertion Electrodes“. In: *Journal of Power Sources* 150.2 (2003), A176. DOI: 10.1149/1.1531194.
- [276] J. Tian, Y. Wang und Z. Chen. „Sensor fault diagnosis for lithium-ion battery packs based on thermal and electrical models“. In: *International Journal of Electrical Power & Energy Systems* 121 (2020), S. 106087. DOI: 10.1016/j.ijepes.2020.106087.
- [277] T. O. Ting, K. L. Man, N. Zhang, C.-U. Lei und C. Lu. „State-Space Battery Modeling for Smart Battery Management System“. In: *Proceedings of the International MultiConference of Engineers and Computer Scientists* 2 (2014).
- [278] M.-K. Tran und M. Fowler. „A Review of Lithium-Ion Battery Fault Diagnostic Algorithms: Current Progress and Future Challenges“. In: *Algorithms* 13.3 (2020), S. 62. DOI: 10.3390/a13030062.
- [279] M.-K. Tran und M. Fowler. „Sensor Fault Detection and Isolation for Degrading Lithium-Ion Batteries in Electric Vehicles Using Parameter Estimation with Recursive Least Squares“. In: *Batteries* 6.1 (2020), S. 1. DOI: 10.3390/batteries6010001.
- [280] L. Trave-Massuyes, T. Escobet und X. Olive. „Diagnosability Analysis Based on Component-Supported Analytical Redundancy Relations“. In: *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans* 36.6 (2006), S. 1146–1160. DOI: 10.1109/TSMCA.2006.878984.

- [281] O. Tremblay und L.-A. Dessaint. „Experimental Validation of a Battery Dynamic Model for EV Applications“. In: *World Electric Vehicle Journal* 3.2 (2009), S. 289–298. DOI: 10.3390/wevj3020289.
- [282] O. Tremblay, L.-A. Dessaint und A.-I. Dekkiche. „A Generic Battery Model for the Dynamic Simulation of Hybrid Electric Vehicles“. In: *2007 IEEE Vehicle Power and Propulsion Conference* (2007), S. 284–289. DOI: 10.1109/VPPC.2007.4544139.
- [283] R. van der Merwe und E. A. Wan. „The square-root unscented Kalman filter for state and parameter-estimation“. In: *IEEE International Conference on Acoustics, Speech, and Signal Processing*. Piscataway, NJ, 2001, S. 3461–3464. DOI: 10.1109/ICASSP.2001.940586.
- [284] E. Vanhatalo. „Multivariate process monitoring of an experimental blast furnace“. In: *Quality and Reliability Engineering International* 26.5 (2010), S. 495–508. DOI: 10.1002/qre.1070.
- [285] H. Wang, Z. Hu und Y. Zhao. „Kernel Principal Component Analysis for Large Scale Data Set“. In: *International Conference on Intelligent Computing* 4113 (2006), S. 745–756. DOI: 10.1007/11816157\_91.
- [286] H. Wang, S. Simunovic, H. Maleki, J. N. Howard und J. A. Hallmark. „Internal configuration of prismatic lithium-ion cells at the onset of mechanically induced short circuit“. In: *Journal of Power Sources* 306 (2016), S. 424–430. DOI: 10.1016/j.jpowsour.2015.12.026.
- [287] Q. Wang, B. Jiang, B. Li und Y. Yan. „A critical review of thermal management models and solutions of lithium-ion batteries for the development of pure electric vehicles“. In: *Renewable and Sustainable Energy Reviews* 64 (2016), S. 106–128. DOI: 10.1016/j.rser.2016.05.033.
- [288] Q. Wang, B. Mao, S. I. Stoliarov und J. Sun. „A review of lithium ion battery failure mechanisms and fire prevention strategies“. In: *Progress in Energy and Combustion Science* 73 (2019), S. 95–131. DOI: 10.1016/j.pecs.2019.03.002.
- [289] Z. Wang, J. Hong, P. Liu und L. Zhang. „Voltage fault diagnosis and prognosis of battery systems based on entropy and Z -score for electric vehicles“. In: *Applied Energy* 196 (2017), S. 289–302. DOI: 10.1016/j.apenergy.2016.12.143.
- [290] E. Warburg. „Ueber das Verhalten sogenannter unpolarisirbarer Elektroden gegen Wechselstrom“. In: *Annalen der Physik und Chemie* 303.3 (1899), S. 493–499. DOI: 10.1002/andp.18993030302.
- [291] G. Welch und G. Bishop. „An Introduction to the Kalman filter: SIGGRAPH 2001 Course 8“. In: *Annual Conference on Computer Graphics & Interactive Techniques*. Los Angeles, CA, USA (August 12-17): ACM Press, Addison-Wesley, 2001.
- [292] C. Weng, J. Sun und H. Peng. „A unified open-circuit-voltage model of lithium-ion batteries for state-of-charge estimation and state-of-health monitoring“. In: *Journal of Power Sources* 258 (2014), S. 228–237. DOI: 10.1016/j.jpowsour.2014.02.026.
- [293] C. K. I. Williams und M. Seeger. „Using the Nyström Method to Speed Up Kernel Machines“. In: *Advances in neural information processing systems* 13 (2000), S. 682–688.
- [294] S. Wold. „Exponentially weighted moving principal components analysis and projections to latent structures“. In: *Chemometrics and Intelligent Laboratory Systems* 23.1 (1994), S. 149–161. DOI: 10.1016/0169-7439(93)E0075-F.
- [295] C. Wu, C. Zhu, Y. Ge und Y. Zhao. „A Review on Fault Mechanism and Diagnosis Approach for Li-Ion Batteries“. In: *Journal of Nanomaterials* 2015 (2015), S. 1–9. DOI: 10.1155/2015/631263.

- [296] B. Xia, Z. Chen, C. Mi und B. Robert. „External short circuit fault diagnosis for lithium-ion batteries“. In: *2014 IEEE Transportation Electrification Conference and Expo (ITEC 2014)*. Piscataway, NJ: IEEE, 2014, S. 1–7. DOI: 10.1109/ITEC.2014.6861806.
- [297] B. Xia und C. Mi. „A fault-tolerant voltage measurement method for series connected battery packs“. In: *Journal of Power Sources* 308 (2016), S. 83–96. DOI: 10.1016/j.jpowsour.2016.01.057.
- [298] B. Xia, T. Nguyen, J. Yang und C. Mi. „The improved interleaved voltage measurement method for series connected battery packs“. In: *Journal of Power Sources* 334 (2016), S. 12–22. DOI: 10.1016/j.jpowsour.2016.09.167.
- [299] B. Xia, Y. Shang, T. Nguyen und C. Mi. „A correlation based fault detection method for short circuits in battery packs“. In: *Journal of Power Sources* 337 (2017), S. 1–10. DOI: 10.1016/j.jpowsour.2016.11.007.
- [300] G. Xia, L. Cao und G. Bi. „A review on battery thermal management in electric vehicle application“. In: *Journal of Power Sources* 367 (2017), S. 90–105. DOI: 10.1016/j.jpowsour.2017.09.046.
- [301] Y. Xie, W. Li, X. Hu, C. Zou, F. Feng und X. Tang. „Novel Mesoscale Electrothermal Modeling for Lithium-Ion Batteries“. In: *IEEE Transactions on Power Electronics* 35.3 (2020), S. 2595–2614. DOI: 10.1109/TPEL.2019.2927014.
- [302] J. Xiong, H. Banvait, Li Lingxi, Y. Chen, J. Xie, Y. Liu, M. Wu und J. Chen. „Failure detection for over-discharged Li-ion batteries“. In: *2012 IEEE International Electric Vehicle Conference*. Hrsg. von I. Staff. IEEE, 2012, S. 1–5. DOI: 10.1109/IEVC.2012.6183238.
- [303] R. Xiong, Q. Yu und W. Shen. „Review on sensors fault diagnosis and fault-tolerant techniques for lithium ion batteries in electric vehicles“. In: *13th IEEE Conference on Industrial Electronics and Applications* (2018), S. 406–410. DOI: 10.1109/ICIEA.2018.8397751.
- [304] R. Xiong, Q. Yu, W. Shen, C. Lin und F. Sun. „A Sensor Fault Diagnosis Method for a Lithium-Ion Battery Pack in Electric Vehicles“. In: *IEEE Transactions on Power Electronics* 34.10 (2019), S. 9709–9718. DOI: 10.1109/TPEL.2019.2893622.
- [305] J. Xu, H. Wang, H. Shi und X. Mei. „Multi-scale short circuit resistance estimation method for series connected battery strings“. In: *Energy* 202 (2020), S. 117647. DOI: 10.1016/j.energy.2020.117647.
- [306] J. Xu, J. Wang, S. Li und B. Cao. „A Method to Simultaneously Detect the Current Sensor Fault and Estimate the State of Energy for Batteries in Electric Vehicles“. In: *Sensors (Basel, Switzerland)* 16.8 (2016), S. 1328. DOI: 10.3390/s16081328.
- [307] Q. Xue, G. Li, Y. Zhang, S. Shen, Z. Chen und Y. Liu. „Fault diagnosis and abnormality detection of lithium-ion battery packs based on statistical distribution“. In: *Journal of Power Sources* 482 (2021), S. 228964. DOI: 10.1016/j.jpowsour.2020.228964.
- [308] N. Yang, X. Zhang, B. Shang und G. Li. „Unbalanced discharging and aging due to temperature differences among the cells in a lithium-ion battery pack with parallel combination“. In: *Journal of Power Sources* 306 (2016), S. 733–741. DOI: 10.1016/j.jpowsour.2015.12.079.
- [309] R. Yang, R. Xiong, H. He und Z. Chen. „A fractional-order model-based battery external short circuit fault diagnosis approach for all-climate electric vehicles application“. In: *Journal of Cleaner Production* 187 (2018), S. 950–959. DOI: 10.1016/j.jclepro.2018.03.259.
- [310] T. Yang, N. Yang, X. Zhang und G. Li. „Investigation of the thermal performance of axial-flow air cooling for the lithium-ion battery pack“. In: *International Journal of Thermal Sciences* 108 (2016), S. 132–144. DOI: 10.1016/j.ijthermalsci.2016.05.009.

- [311] L. Yao, Z. Fang, Y. Xiao, J. Hou und Z. Fu. „An Intelligent Fault Diagnosis Method for Lithium Battery Systems Based on Grid Search Support Vector Machine“. In: *Energy* 214 (2021), S. 118866. DOI: 10.1016/j.energy.2020.118866.
- [312] L. Yao, Z. Wang und J. Ma. „Fault detection of the connection of lithium-ion power batteries based on entropy for electric vehicles“. In: *Journal of Power Sources* 293 (2015), S. 548–561. DOI: 10.1016/j.jpowsour.2015.05.090.
- [313] L. Yao, Y. Xiao, X. Gong, J. Hou und X. Chen. „A novel intelligent method for fault diagnosis of electric vehicle battery system based on wavelet neural network“. In: *Journal of Power Sources* 453 (2020), S. 227870. DOI: 10.1016/j.jpowsour.2020.227870.
- [314] Y. Ye, Y. Shi, N. Cai, J. Lee und X. He. „Electro-thermal modeling and experimental validation for lithium ion battery“. In: *Journal of Power Sources* 199 (2012), S. 227–238. DOI: 10.1016/j.jpowsour.2011.10.027.
- [315] S. Yin, S. X. Ding, A. Haghani, H. Hao und P. Zhang. „A comparison study of basic data-driven fault diagnosis and process monitoring methods on the benchmark Tennessee Eastman process“. In: *Journal of Process Control* 22.9 (2012), S. 1567–1581. DOI: 10.1016/j.jprocont.2012.06.009.
- [316] S. Yin, S. X. Ding, X. Xie und H. Luo. „A Review on Basic Data-Driven Approaches for Industrial Process Monitoring“. In: *IEEE Transactions on Industrial Electronics* 61.11 (2014), S. 6418–6428. DOI: 10.1109/TIE.2014.2301773.
- [317] C. Zhang, K. Li, S. Mcloone und Z. Yang. „Battery modelling methods for electric vehicles - A review“. In: *2014 European Control Conference* (2014), S. 2673–2678. DOI: 10.1109/ECC.2014.6862541.
- [318] G. Zhang, X. Wei, X. Tang, J. Zhu, S. Chen und H. Dai. „Internal short circuit mechanisms, experimental approaches and detection methods of lithium-ion batteries for electric vehicles: A review“. In: *Renewable and Sustainable Energy Reviews* 141 (2021), S. 110790. DOI: 10.1016/j.rser.2021.110790.
- [319] H. Zhang, L. Pei, J. Sun, K. Song, R. Lu, Y. Zhao, C. Zhu und T. Wang. „Online Diagnosis for the Capacity Fade Fault of a Parallel-Connected Lithium Ion Battery Group“. In: *Energies* 9.5 (2016), S. 387. DOI: 10.3390/en9050387.
- [320] X. Zhang, W. Hu, Z. Zhao, Y.-g. Wang, X. Li und Q. Wei. „SVD based Kalman particle filter for robust visual tracking“. In: *19th International Conference on Pattern Recognition* (2008), S. 1–4. DOI: 10.1109/ICPR.2008.4761153.
- [321] Z. Zhang, X. Kong, Y. Zheng, L. Zhou und X. Lai. „Real-time diagnosis of micro-short circuit for Li-ion batteries utilizing low-pass filters“. In: *Energy* 166 (2019), S. 1013–1024. DOI: 10.1016/j.energy.2018.10.160.
- [322] Y. Zhao, P. Liu, Z. Wang, L. Zhang und J. Hong. „Fault and defect diagnosis of battery for electric vehicles based on big data analysis methods“. In: *Applied Energy* 207 (2017), S. 354–362. DOI: 10.1016/j.apenergy.2017.05.139.
- [323] C. Zheng, Z. Chen und D. Huang. „Fault diagnosis of voltage sensor and current sensor for lithium-ion battery pack using hybrid system modeling and unscented particle filter“. In: *Energy* 191 (2020), S. 116504. DOI: 10.1016/j.energy.2019.116504.
- [324] C. Zheng, Y. Ge, Z. Chen, D. Huang, J. Liu und S. Zhou. „Diagnosis Method for Li-Ion Battery Fault Based on an Adaptive Unscented Kalman Filter“. In: *Energies* 10.11 (2017), S. 1810. DOI: 10.3390/en10111810.

- [325] Y. Zheng, X. Han, L. Lu, J. Li und M. Ouyang. „Lithium ion battery pack power fade fault identification based on Shannon entropy in electric vehicles“. In: *Journal of Power Sources* 223 (2013), S. 136–146. DOI: 10.1016/j.jpowsour.2012.09.015.
- [326] Y. Zheng, Y. Lu, W. Gao, X. Han, X. Feng und M. Ouyang. „Micro-Short-Circuit Cell Fault Identification Method for Lithium-Ion Battery Packs Based on Mutual Information“. In: *IEEE Transactions on Industrial Electronics* 68.5 (2021), S. 4373–4381. DOI: 10.1109/TIE.2020.2984441.
- [327] Y. Zheng, M. Ouyang, L. Lu, J. Li, X. Han, L. Xu, H. Ma, T. A. Dollmeyer und V. Freyermuth. „Cell state-of-charge inconsistency estimation for LiFePO<sub>4</sub> battery pack in hybrid electric vehicles using mean-difference model“. In: *Applied Energy* 111 (2013), S. 571–580. DOI: 10.1016/j.apenergy.2013.05.048.
- [328] L. Zhou, Y. Zheng, M. Ouyang und L. Lu. „A Simulation Study on Parameter Variation Effects in Battery Packs for Electric Vehicles“. In: *Energy Procedia* 105 (2017), S. 4470–4475. DOI: 10.1016/j.egypro.2017.03.949.
- [329] L. Zhou, Y. Zheng, M. Ouyang und L. Lu. „A study on parameter variation effects on battery packs for electric vehicles“. In: *Journal of Power Sources* 364 (2017), S. 242–252. DOI: 10.1016/j.jpowsour.2017.08.033.
- [330] J. Ziegmann, M. Schmid und C. Endisch. „Sensitivity Analysis for Driver Energy Prediction with Environmental Features and Naturalistic Data“. In: *2018 IEEE 22nd International Conference on Intelligent Engineering Systems (INES)*. IEEE, 2018, S. 000199–000206. DOI: 10.1109/INES.2018.8523987.
- [331] T. Zimmermann, P. Keil, M. Hofmann, M. F. Horsche, S. Pichlmaier und A. Jossen. „Review of system topologies for hybrid electrical energy storage systems“. In: *Journal of Energy Storage* 8 (2016), S. 78–90. DOI: 10.1016/j.est.2016.09.006.



## Wissenschaftliche Publikationen des Autors

Die wissenschaftlichen Beiträge dieser Arbeit wurden in Fachjournals und Tagungsbeiträgen publiziert, patentiert, sowie in Form von Präsentationen und Postern der wissenschaftlichen Fachöffentlichkeit vorgestellt. Die nachfolgenden Abschnitte bieten eine Übersicht über die Veröffentlichungen als Erst- und Koautor.

### Journals (peer-reviewed)

- [245] **M. Schmid**, U. Vögele und C. Endisch. „A novel matrix-vector-based framework for modeling and simulation of electric vehicle battery packs“. In: *Journal of Energy Storage* 32 (2020), S. 101736. DOI: 10.1016/j.est.2020.101736.
- [237] **M. Schmid**, E. Gebauer und C. Endisch. „Structural Analysis in Reconfigurable Battery Systems for Active Fault Diagnosis“. In: *IEEE Transactions on Power Electronics* 36.8 (2021), S. 8672–8684. DOI: 10.1109/TPEL.2021.3049573.
- [238] **M. Schmid**, E. Gebauer, C. Hanzl und C. Endisch. „Active Model-Based Fault Diagnosis in Reconfigurable Battery Systems“. In: *IEEE Transactions on Power Electronics* 36.3 (2021), S. 2584–2597. DOI: 10.1109/TPEL.2020.3012964.
- [240] **M. Schmid**, H.-G. Kneidinger und C. Endisch. „Data-Driven Fault Diagnosis in Battery Systems Through Cross-Cell Monitoring“. In: *IEEE Sensors Journal* 21.2 (2021), S. 1829–1837. DOI: 10.1109/JSEN.2020.3017812.
- [239] **M. Schmid**, J. Kleiner und C. Endisch. „Early detection of Internal Short Circuits in series-connected battery packs based on nonlinear process monitoring“. In: *Journal of Energy Storage* 48 (2022), S. 103732. DOI: 10.1016/j.est.2021.103732.
- [235] **M. Schmid** und C. Endisch. „Online diagnosis of soft internal short circuits in series-connected battery packs using modified kernel principal component analysis“. In: *Journal of Energy Storage* 53 (2022), S. 104815. DOI: 10.1016/j.est.2022.104815.
- [144] J. Kleiner, R. Singh, **M. Schmid**, L. Komsijska, G. Elger und C. Endisch. „Influence of Heat Pipe Assisted Terminal Cooling on the Thermal Behavior of a Large Prismatic Lithium-Ion Cell during Fast Charging in Electric Vehicles“. In: *Applied Thermal Engineering* (2020), S. 116328. DOI: 10.1016/j.applthermaleng.2020.116328.
- [107] C. Hanzl, C. Hartmann, M. Hölzle, B. Liebhart, **M. Schmid** und C. Endisch. „Current Commutation in a Switched Lithium-Ion Cell used in Cascaded Half-Bridge Multilevel Inverters“. In: *IET Power Electronics* 14.6 (2021), S. 1073–1088. DOI: 10.1049/pe12.12088.
- [146] L. Komsijska, T. Buchberger, S. Diehl, M. Ehrensberger, C. Hanzl, C. Hartmann, M. Hölzle, J. Kleiner, M. Lewerenz, B. Liebhart, **M. Schmid**, D. Schneider, S. Speer, J. Stöttner, C. Terbrack, M. Hinterberger und C. Endisch. „Critical Review of Intelligent Battery Systems: Challenges, Implementation, and Potential for Electric Vehicles“. In: *Energies* 14.18 (2021), S. 5989. DOI: 10.3390/en14185989.

## Tagungsbände (peer-reviewed)

- [241] **M. Schmid**, B. Liebhart, J. Kleiner, C. Endisch und R. Kennel. „Online Detection of Soft Internal Short Circuits in Lithium-Ion Battery Packs by Data-Driven Cell Voltage Monitoring“. In: *2021 IEEE 12th Energy Conversion Congress & Exposition - Asia (ECCE-Asia)*. IEEE, 2021, S. 1711–1718. DOI: 10.1109/ECCE-Asia49820.2021.9479175.
- [330] J. Ziegmann, **M. Schmid** und C. Endisch. „Sensitivity Analysis for Driver Energy Prediction with Environmental Features and Naturalistic Data“. In: *2018 IEEE 22nd International Conference on Intelligent Engineering Systems (INES)*. IEEE, 2018, S. 000199–000206. DOI: 10.1109/INES.2018.8523987.
- [163] B. Liebhart, S. Diehl, **M. Schmid**, C. Endisch und R. Kennel. „Improved Impedance Measurements for Electric Vehicles with Reconfigurable Battery Systems“. In: *2021 IEEE 12th Energy Conversion Congress & Exposition - Asia (ECCE-Asia)*. IEEE, 2021, S. 1736–1742. DOI: 10.1109/ECCE-Asia49820.2021.9479060.
- [274] M. Theiler, M. Lewerenz und **M. Schmid**. „Investigation of the Float Current Analysis and the Float Current Settling Process via DVA on 18650 Li(NiCoAl)O<sub>2</sub>/Graphite Cells“. In: *Applied Research Conference 2021*. Hrsg. von M. Söllner und G. Pirkl. 2021, S. 463–468.

## Poster

- [236] **M. Schmid** und C. Endisch. „Parameterization of real-time capable models for the electrical-thermal simulation of battery behavior [Poster]“. In: *Advanced Automotive Battery Conference (AABC) Europe*. 2020.
- [234] **M. Schmid** und C. Endisch. „Control-Oriented Modeling and Simulation of Large-Scale Electric Vehicle Battery Packs [Poster]“. In: *12. Internationale Fachtagung „Kraftwerk Batterie – Advanced Battery Power“*. 2020.

## Betreute Abschlussarbeiten

- [116] S. Hillebrand. „Parameteridentifikation für Batteriezellen“. Masterarbeit. München: Technischen Universität München, Fakultät für Elektro- und Informationstechnik, 2019.
- [227] M. Raba. „Skriptbasierte Modellierung einer elektrischen Antriebskomponente“. Masterarbeit. Ingolstadt: Technische Hochschule Ingolstadt, Institut für Innovative Mobilität, 2019.
- [145] H.-G. Kneidinger. „Datengetriebene Zellüberwachung zur Fehlerdiagnose in Batteriesystemen“. Masterarbeit. München: Technischen Universität München, Fakultät für Elektro- und Informationstechnik, 2019.
- [89] E. Gebauer. „Model-Based Fault Diagnosis in Reconfigurable Battery Systems“. Masterarbeit. München: Technischen Universität München, Fakultät für Elektro- und Informationstechnik, 2020.
- [90] E. Gebauer. „Modellbasierte Fehlerdiagnose in verteilten Systemen“. Forschungspraxis. München: Technischen Universität München, Fakultät für Elektro- und Informationstechnik, 2019.



## Patentanmeldungen

- [242] **M. Schmid**, B. Liebhart, D. Schneider, M. Hinterberger und C. Endisch. „Verfahren zur Bestimmung zumindest eines Batterieparameters einer Batterie, entsprechend betreibbare Batterie sowie Kraftfahrzeug“. DE102019201604A1. Deutsches Patent- und Markenamt. 7.02.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192016049>.
- [243] **M. Schmid**, D. Schneider, M. Hinterberger und C. Endisch. „Verfahren zum Durchführen eines Batterietests in einer Batterie eines Kraftfahrzeugs sowie Batterie und Kraftfahrzeug“. DE102019202463A1. Deutsches Patent- und Markenamt. 22.02.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192024637>.
- [249] D. Schneider, **M. Schmid**, U. Vögele, M. Hinterberger und C. Endisch. „Verfahren zum Bestimmen eines Werts einer physikalischen Größe einer Zellanordnung, Bestimmungseinrichtung, Hochvoltbatterie und Kraftfahrzeug“. DE102019207354A1. Deutsches Patent- und Markenamt. 20.05.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192073549>.
- [244] **M. Schmid**, C. Terbrack, M. Hinterberger und C. Endisch. „Verfahren und Steuervorrichtung zum Betreiben zumindest einer Batteriezelle eines Batteriesystems eines Kraftfahrzeug“. DE102019210213A1. Deutsches Patent- und Markenamt. 10.07.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192102131>.
- [165] B. Liebhart, C. Terbrack, **M. Schmid**, D. Schneider, M. Hinterberger und C. Endisch. „Verfahren zum Betreiben eines Batteriesystems für ein Kraftfahrzeug, um eine Diagnosemessung durchzuführen, sowie Batteriesystem für ein Kraftfahrzeug und Kraftfahrzeug“. DE102019211082A1. Deutsches Patent- und Markenamt. 25.07.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192110827>.
- [248] **M. Schmid**, U. Vögele, D. Schneider, M. Hinterberger und C. Endisch. „Verfahren zum Erkennen eines Sensorausfalls in einem Batteriesystem eines Kraftfahrzeugs sowie Batteriesystem und Kraftfahrzeug“. DE102019211998A1. Deutsches Patent- und Markenamt. 9.08.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192119980>.
- [247] **M. Schmid**, U. Vögele, D. Schneider, M. Hinterberger und C. Endisch. „Verfahren zum Detektieren eines Fehlers in einem Batteriesystem sowie Batteriesystem und Kraftfahrzeug“. DE102019212909A1. Deutsches Patent- und Markenamt. 28.08.2019. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020192129099>.
- [246] **M. Schmid**, U. Vögele, M. Hinterberger und C. Endisch. „Verfahren zum Betreiben einer Energiespeicheranordnung sowie entsprechende Energiespeicheranordnung“. DE102020112437A1. Deutsches Patent- und Markenamt. 7.05.2020. URL: <https://register.dpma.de/DPMAREGISTER/pat/register?AKZ=1020201124376>.

